


UNIVERSIDADE FEDERAL DO PARANÁ

ETHEL RUBIN DE CELIS LLANOS

MODELOS DE CLASIFICACIÓN PARA DETECCIÓN DEL CAMBIO DE USO DE
LA TIERRA EN LA AMAZONIA PERUANA

CURITIBA

2019



ETHEL RUBIN DE CELIS LLANOS

MODELOS DE CLASIFICACIÓN PARA DETECCIÓN DEL CAMBIO DE USO DE
LA TIERRA EN LA AMAZONIA PERUANA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do Título de Doutor em Engenharia Florestal, Área de Concentração em Tecnologia e Utilização de Produtos Florestais.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Nelson Carlos Rosot
Prof. Dr. Hideo Araki

CURITIBA

2019

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Rubin de Celis Llanos, Ethel

Modelos de clasificación para detección del cambio de uso de la tierra
en la Amazonia Peruana / Ethel Rubin de Celis Llanos. - Curitiba, 2019.
153 f. : il.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Nelson Carlos Rosot

Prof. Dr. Hideo Araki

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências
Agrárias, Programa de Pós-Graduação em Engenharia Florestal.

Defesa: Curitiba, 19/12/2019.

Área de concentração: Manejo Florestal.

1. Florestas - Peru. 2. Mapeamento florestal - Peru. 3. Sensoriamento
remoto. 4. Algoritmos. 5. Processamento de imagens. 6. Teses. I. Dalla
Corte, Ana Paula. II. Rosot, Nelson Carlos. III. Araki, Hideo. IV. Universidade
Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

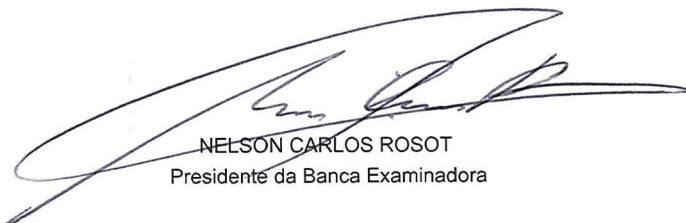
CDU – 634.0.58(85)

TERMO DE APROVAÇÃO

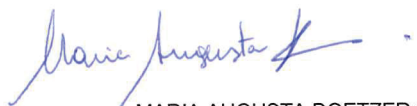
Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **ETHEL RUBIN DE CELIS LLANOS** intitulada: **MODELOS DE CLASIFICACIÓN PARA DETECCIÓN DEL CAMBIO DE USO DE LA TIERRA EN LA AMAZONIA PERUANA**, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 19 de Dezembro de 2019.




NELSON CARLOS ROSOT
Presidente da Banca Examinadora



MARIA AUGUSTA DOETZER ROSOT
Avaliador Externo (EMPRESA BRASILEIRA DE PESQUISA
AGROPECUÁRIA)



HIDEO ARAKI
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)



RODRIGO DE CAMPOS MACEDO
Avaliador Externo (null)



NELSON YOSHIHIRO NAKAJIMA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

A mi gran Dios, solo con su gran poder y misericordia estoy viva, y al motor de mi vida Alejandro.

AGRADECIMIENTO

Todo mi agradecimiento a mi orientadora Dra. Ana Paula Dalla Corte por su dedicación y experiencia brindada en el desarrollo de mi tesis.

A mi Co-orientador y amigo Dr. Nelson Carlos Rosot quien siempre me animó a seguir adelante, aunque los tiempos no fueran fáciles.

A Hideo Araki por las correcciones y pautas para terminar satisfactoriamente el doctorado.

Al Postgrado en Ingeniería Forestal de la Universidad Federal de Paraná, por darme la oportunidad de realizar mi doctorado.

Agradezco al Ing. Carlos Salinas Montes Coordinador Regional Proyecto Monitoreo de la Deforestación, Aprovechamiento Forestal y Cambios en el Uso del Suelo en el Bosque Pan amazónico de la OTCA, y Ing. Rocío Malleux quienes me dieron la oportunidad de trabajar en la Sala de Observación Perú y ganar experiencia en diferentes temas.

Al Vice-Rectorado de Investigación de la Universidad Nacional Agraria La Molina por su apoyo financiero para la fase de campo por medio del Ministerio de Educación del Perú.

Al Ingeniero Víctor Barrena Arroyo, colega, jefe y amigo que siempre vio la manera de apoyarme en la adquisición del programa de interpretación de imágenes, así como en las solicitudes de imágenes de alta resolución al estado peruano.

A KENÉ Instituto de Estudios Forestales y Ambientales por su apoyo en las actividades de campo, así como el apoyo en la traducción del artículo científico en las personas de Lucila Pautrat y Guillermo Cuellar.

Al Herbario-MOL de la UNALM en la persona del PhD. Carlos Reynel y Ing. Sonia Palacios, gracias al préstamo de equipos para unir las fotografías aéreas tomadas en el sobrevuelo realizado.

Asociación para la conservación de la cuenca amazónica ACCA en la persona de Sidney Novoa quien donó una imagen PLANET para la investigación realizada.

Al Ing. Wilfredo Ojeda quien me animó en todo momento para seguir, pese a mil cosas que se presentaron en el camino.

Veinte años después, y tan presente en la última parte de este trabajo, gracias por el ánimo y acompañamiento a la distancia.

Y a mis amores Etelvina, Pedro, Diana y Annie que siempre me apoyaron en todo sentido para realizar esta investigación, así como mis grandes amigas Zoila, Maribel, Berenice, Alejandra, Lasmit, Belith y Rossana.

RESUMO

A área de estudo da presente investigação foi o distrito de Nueva Requena, localizado na província de Coronel Portillo, no departamento de Ucayali, Peru. O distrito de Nueva Requena, bem como diferentes áreas da bacia amazônica, atualmente enfrenta uma mudança alarmante na cobertura florestal e no uso da terra, gerando mudanças significativas nos processos ambientais. Nesse contexto, é necessário implementar um sistema de monitoramento que utilize modelos de classificação supervisionados capazes de proporcionar informações de qualidade e confiáveis sobre a mudança no uso da terra. Nesta pesquisa foram utilizadas imagens passivas de satélite Sentinel-2A, imagens ativas do Sentinel-1A e a fusão de ambas, e foram aplicados dois algoritmos: Support Vector Machine (SVM) no módulo de Análise de Objetos e o algoritmo Boosting ou árvores de decisão. Foram realizadas 83 classificações supervisionadas com os referidos algoritmos, e foi selecionado o modelo mais apropriado para determinar a mudança no uso da terra. O melhor modelo de classificação foi o denominado como C6C7, gerado com imagens de satélite passivas Sentinel-2A. Os algoritmos foram executados separadamente e, em seguida, foi executada a álgebra de mapa para gerar a mudança no uso da terra; a classificação supervisionada C6 foi realizada com o algoritmo boosting com partição de amostra em 80% de treinamento e 20% de teste para três bandas espectrais do ano de 2016, e a classificação supervisionada C7 com o algoritmo Support Vector Machine (SVM) sendo as entradas as medianas das três bandas do ano de 2018. Este modelo apresentou o menor erro de classificação, de 22,7%, sendo que a validação foi realizada com imagens de alta resolução PeruSat- 1 para o ano de 2018 e imagens do Google Earth para o ano de 2016, fornecendo um índice Kappa de 0,607 e a porcentagem corretamente classificada (PCC) de 86,10% para o ano de 2016 e o índice Kappa de 0,560 e a porcentagem corretamente classificada (PCC) de 82,30 % para o ano de 2018, demonstrando concordância considerável e moderada, respectivamente.

Palavras-chave: Sentinel. PERUSAT-1. *Support Vector Machine* (SVM). *Boosting* (árvores de decisão).

ABSTRACT

The area of study of the present investigation was the Nueva Requena district, located in the province of Coronel Portillo, in the department of Ucayali, Peru. The Nueva Requena district, as well as different areas of the Amazon basin, currently faces an alarming change in forest cover and land use, generating significant changes in environmental processes. In this context, it is necessary to implement a monitoring system that uses supervised classification models capable of providing quality and reliable information on land use change. In this research, passive satellite images Sentinel-2A, active images from Sentinel-1A and the fusion of both were used, and two algorithms were applied: Support Vector Machine (SVM) in the Object Analysis module and the Boosting algorithm or decision trees. 83 supervised classifications were carried out with the referred algorithms, and the most appropriate model was selected to determine the change in land use. The best classification model was named C6C7, generated with passive satellite images Sentinel-2A. The algorithms were run separately and then map algebra was performed to generate the change in land use; the supervised classification C6 was performed with the boosting algorithm with sample partition at 80% training and 20% testing for three spectral bands in the year 2016, and the supervised classification C7 with the Support Vector Machine (SVM) algorithm being the inputs the medians of the three bands of the year 2018. This model had the lowest classification error, of 22.7%, and the validation was performed with high resolution images PeruSat- 1 for the year 2018 and images from Google Earth for the year 2016, providing a Kappa index of 0.607 and the correctly classified percentage (PCC) of 86.10% for the year 2016 and the Kappa index of 0.560 and the correctly classified percentage (PCC) of 82.30% for the year 2018, showing considerable and moderate agreement, respectively.

Key words: Sentinel. PERUSAT-1. *Support Vector Machine* (SVM). *Boosting* (decision trees).

RESUMEN

El área de estudio de la presente investigación fue el distrito de Nueva Requena, ubicado en la provincia de Coronel Portillo, en el departamento de Ucayali, Perú. El distrito de Nueva Requena, así como diferentes áreas de la cuenca del Amazonas, actualmente enfrenta un cambio alarmante en la cubierta forestal y el uso de la tierra, generando cambios significativos en los procesos ambientales. En este contexto, es necesario implementar un sistema de monitoreo que utilice modelos de clasificación supervisados capaces de proporcionar información confiable y de calidad sobre el cambio de uso del suelo. En esta investigación, se utilizaron imágenes pasivas del satélite Sentinel-2A, imágenes activas de Sentinel-1A y la fusión de ambas, y se aplicaron dos algoritmos: *Support Vector Machine* (SVM) en el módulo Object Analysis y el algoritmo *Boosting* o árboles de decisión. Se realizaron 83 clasificaciones supervisadas con los algoritmos mencionados, y se seleccionó el modelo más apropiado para determinar el cambio en el uso del suelo. El mejor modelo de clasificación se denominó C6C7, generado con imágenes satelitales pasivas Sentinel-2A. Los algoritmos se ejecutaron por separado y luego se realizó el álgebra de mapas para generar el cambio en el uso de la tierra; la clasificación supervisada C6 se realizó con el algoritmo de refuerzo con partición de muestra al 80% de entrenamiento y 20% de pruebas para tres bandas espectrales en el año 2016, y la clasificación supervisada C7 con el algoritmo de máquina de vectores de soporte (SVM) como entradas las medianas de las tres bandas del año 2018. Este modelo tuvo el error de clasificación más bajo, del 22.7%, y la validación se realizó con imágenes de alta resolución PeruSat-1 para el año 2018 e imágenes de Google Earth para el año 2016, proporcionando un índice Kappa de 0.607 y el porcentaje correctamente clasificado (PCC) de 86.10% para el año 2016 y el índice Kappa de 0.560 y el porcentaje correctamente clasificado (PCC) de 82.30% para el año 2018, mostrando un acuerdo considerable y moderado, respectivamente.

Palabras-clave: Sentinel. PERUSAT-1. *Support Vector Machine* (SVM). *Boosting* (árboles de decisión).

LISTA DE FIGURAS

FIGURA 1 - OCHO REGIONES NATURALES DEL PERÚ.....	28
FIGURA 2 - PROTOCOLO RAISG PARA EL ANÁLISIS DE LA DEFORESTACIÓN EN LA PAN- AMAZONÍA.....	36
FIGURA 3 - SERIE TEMPORAL LANDSAT 2010 – 2015.....	40
FIGURA 4 - APERTURA SINTÉTICA	50
FIGURA 5 - PRODUCTOS ADQUIRIDOS POR Sentinel-1	53
FIGURA 6 - REPRESENTACIÓN ARTÍSTICA DEL SATÉLITE PERUANO	56
FIGURA 7 - CRITERIO DE VISUALIZACIÓN DE IMÁGENES.....	61
FIGURA 8 - DISPERSIÓN DEL ALGORITMO DISTANCIAS MÍNIMAS	63
FIGURA 9 - DISPERSIÓN DEL ALGORITMO PARALELEPÍPEDO	64
FIGURA 10 - DISPERSIÓN DEL ALGORITMO MÁXIMA PROBABILIDAD.....	65
FIGURA 11 - ESTRUCTURA DE UN ÁRBOL DE DECISIÓN.....	66
FIGURA 12 - ÁREA DE ENTRENAMIENTO Y TRATAMIENTO EN ARBOLES DE DECISIÓN.....	66
FIGURA 13 - ESTRUCTURA DE <i>SUPPORT VECTOR MACHINE</i>	67
FIGURA 14 - UBICACIÓN DEL DISTRITO DE NUEVA REQUENA	74
FIGURA 15 - FLUJO DEL PROCESO METODOLÓGICO	76
FIGURA 16 - MAPA CORTE DEL MOSAICO Sentinel-2A AÑO 2016	89
FIGURA 17 - MAPA CORTE DEL MOSAICO Sentinel-2A AÑO 2018.....	90
FIGURA 18 - MAPA CORTE Sentinel-1A AÑO 2015.....	90
FIGURA 19 - MAPA CORTE Sentinel-1A AÑO 2019.....	91
FIGURA 20 - SEGMENTACIÓN DEL MOSAICO 2016.....	92
FIGURA 21 - EJEMPLO DE ASIGNACIÓN DE CÓDIGOS CLASIFICACIÓN	92
FIGURA 22 - CLAVE DE IDENTIFICACIÓN EN IMÁGENES SATELITALES.....	93
FIGURA 23 - MODELO 1 - MOSAICO 2016	95
FIGURA 24 - MODELO 1 - MOSAICO 2018	95
FIGURA 25 - CAMBIO DE USO DE LA TIERRA MODELO 1	96
FIGURA 26 - MODELO 2 - IMAGEN DE RADAR 2015	98
FIGURA 27 - MODELO 2 - IMAGEN DE RADAR 2019	99
FIGURA 28 - CAMBIO DE USO DE LA TIERRA MODELO 2	100
FIGURA 29 - MODELO 3 - FUSIÓN DE MOSAICO 2016 Y 2018	103

FIGURA 30 - CAMBIO DE USO DE LA TIERRA MODELO 3	104
FIGURA 31 - MODELO 4 – <i>SUPPORT VECTOR MACHINE</i> (SVM)	105
FIGURA 32 - MODELO 4 - <i>BOOSTING</i>	106
FIGURA 33 - CAMBIO DE USO DE LA TIERRA MODELO 4	107
FIGURA 34 - MAPA DE IMÁGENES DE ALTA RESOLUCIÓN USADAS EN LA VALIDACIÓN 2018.....	115
FIGURA 35 - MAPA DE FOTOGRAFÍAS AÉREAS USADAS EN LA VALIDACIÓN 2018	116
FIGURA 36 - IMAGEN GOOGLE EARTH 2016 USADAS EN LA VALIDACIÓN 2016	116
FIGURA 37 - PUNTOS DE VALIDACIÓN DISTRITO DE NUEVA REQUENA...	117
FIGURA 38 - MAPA DE LA CLASIFICACIÓN C6C7 – MODELO 1	125

LISTA DE TABLAS

TABLA 1 - CAUSAS DIRECTAS DE LA DEFORESTACIÓN EN BOSQUES AMAZÓNICOS PERUANOS	32
TABLA 2 - CAUSAS INDIRECTAS DE LA DEFORESTACIÓN EN BOSQUES AMAZÓNICOS PERUANOS	33
TABLA 3 - BANDAS UTILIZADAS POR LOS SISTEMAS DE RADAR CON SUS RESPECTIVAS LONGITUDES DE ONDA Y FRECUENCIAS	45
TABLA 4 - CARACTERÍSTICAS DE LOS SISTEMAS DE RADAR DE APERTURA SINTÉTICA(SAR)	51
TABLA 5 - CARACTERÍSTICAS DEL SENSOR Sentinel-1	52
TABLA 6 - BANDAS ESPECTRALES DEL SENSOR Sentinel-2A.....	54
TABLA 7 - CARACTERÍSTICAS DEL SENSOR PERÚSAT-1	56
TABLA 8 - CARACTERÍSTICAS DEL SENSOR PLANET	57
TABLA 9 - TIPOS DE <i>SUPPORT VECTOR MACHINE</i> (SVM)	68
TABLA 10 - VALORACIÓN DEL ÍNDICE KAPPA	72
TABLA 11 - PUNTOS EXTREMOS DEL DEPARTAMENTO DE UCAYALI	73
TABLA 12 - FRONTERAS DEL DISTRITO DE NUEVA REQUENA	75
TABLA 13 - EQUIPOS, PROGRAMAS E INSUMOS	75
TABLA 14 - CARACTERÍSTICAS ESPECTRALES DE LAS BANDAS DEL SENSOR Sentinel- 2A.....	77
TABLA 15 - CARACTERÍSTICA ESPECTRAL DEL SENSOR Sentinel-1A.....	77
TABLA 16 - CLAVE DE IDENTIFICACIÓN DE USO DE LA TIERRA	79
TABLA 17 - GENERACIÓN DE LAS ÁREAS DE ENTRENAMIENTO (AE).....	80
TABLA 18 - CLASIFICACIÓN MEDIANTE EL ALGORITMO <i>SUPPORT VECTOR MACHINE</i> (SVM).....	80
TABLA 19 - CLASIFICACIÓN MEDIANTE EL ALGORITMO <i>BOOSTING</i>	81
TABLA 20 - CLAVE DE IDENTIFICACIÓN DEL CAMBIO DE USO DE LA TIERRA	84
TABLA 21 - ERROR DE GENERACIÓN - MOSAICO Sentinel-2A (2016)	88
TABLA 22 - ERROR DE GENERACIÓN - MOSAICO Sentinel-2A (2018)	89
TABLA 23 - SEGMENTOS O ÁREA DE ENTRENAMIENTO POR MODELO	94
TABLA 24 - VARIABLE O ATRIBUTOS DE LOS MOSAICOS PASIVOS	94

TABLA 25 - TASA DE ERROR DEL MODELO 1	109
TABLA 26 - TASA DE ERROR DEL MODELO 2	111
TABLA 27 - ANÁLISIS ESTADÍSTICO DEL MODELO 3	112
TABLA 28 - ANÁLISIS ESTADÍSTICO DEL MODELO 4	113
TABLA 29 - IMÁGENES SATELITALES DE VALIDACIÓN.....	114
TABLA 30 - ÍNDICE KAPPA Y PCC DEL MODELO 1	118
TABLA 31 - INDICE KAPPA Y PCC DEL MODELO 2	120
TABLA 32 - ÍNDICE KAPPA Y PCC DEL MODELO 3	121
TABLA 33 - ÍNDICE KAPPA Y PCC DEL MODELO 4	122
TABLA 34 - MATRIZ DE CONFUSIÓN C6 AÑO 2016.....	123
TABLA 35 - MATRIZ DE CONFUSIÓN C7 AÑO 2018.....	124

LISTA DE ABREVIATURAS

ACCA	- Asociación para la Conservación de la Cuenca Amazónica
AIRBUS	- Airbus Defence and Space
CCRS	- Centro Canadiense de Percepción Remota
CIV	- Campo instantáneo de vista
CNUCC	- Convención de las Naciones Unidas Contra la Corrupción
CNOIS	- Centro Nacional de Operaciones de Imágenes Satelitales
CONIDA	- Agencia Espacial del Perú
ESA	- Agencia Espacial Europea
FAO	- Organización de las Naciones Unidas para la Alimentación
GORE	- Gobierno Regional
GTPI	- Plan de Acción para la Prevención y Control de la Deforestación en la Amazonía legal
IBAMA	- el Instituto Brasileño del Medio Ambiente y Recursos Naturales Renovables
IBM	- International Business Machines Corporation
IGN	- Instituto Geográfico Nacional
INEI	- Instituto Nacional de Estadística e Informática del Perú
IPCC	- Grupo Intergubernamental de Expertos sobre el Cambio Climático
KENÉ	- Instituto de Estudios Forestales y Ambientales
MAAP	- Proyecto de Monitoreo de los Andes Amazónicos
MCTIC	- Ministerio de Ciencia, Tecnología, Innovaciones y Comunicaciones
MMA	- Ministerio del Medio Ambiente de Brasil
MINAM	- Ministerio del Ambiente del Perú
MINAGRI	- Ministerio de Agricultura y Riego del Perú
NASA	- Administración Nacional de la Aeronáutica y del Espacio
MTC	- Ministerio de Transportes y Comunicaciones del Perú
OSINFOR	- Organismo de Supervisión de los Recursos Forestales
OTCA	- Organización de Tratado de Cooperación Amazónica

PCC	- Porcentaje correctamente clasificado
PNCBMCC	- Programa Nacional de Conservación de Bosques para la Mitigación del Cambio Climático
PNUMA	- Programa de las Naciones Unidas para el Medio Ambiente
RAISG	- Red Amazónica de información Socioambiental georreferenciada
SAR	- Sistema de RADAR de Abertura Sintética
SLAR	- Side Looking Airbone RADAR
SERFOR	- Servicio Nacional Forestal y de Fauna Silvestre del Perú
SERNAP	- Servicio Nacional de Áreas Protegidas del Perú
SVM	- Support Vector Machine
RAR	- Sistema RADAR de Apertura Real
RMS	- Error Medio Cuadrático
UNALM	- Universidad Nacional Agraria La Molina

INDICE

1	INTRODUCCIÓN	23
1.1	OBJETIVOS	24
1.2	HIPÓTESIS	25
2	REVISIÓN DE LITERATURA	26
2.1	ASPECTOS CONCEPTUALES	26
2.1.1	Concepto de Bosque.....	26
2.1.2	Bosque húmedo tropical.....	27
2.2	DEFORESTACIÓN	28
2.2.1	Expansión agropecuaria.....	29
2.2.2	Expansión urbana	30
2.2.3	Perturbación.....	30
2.3	EFFECTOS DE LA DEFORESTACIÓN	31
2.4	TÉCNICAS DE DETECCIÓN DE DATOS.....	33
2.4.1	Trabajos realizados de detección de Deforestación.....	33
2.5	CAMBIO DE USO DE LA TIERRA.....	38
2.6	TELEDETECCIÓN	40
2.6.1	Sensores pasivos	41
2.6.1.1	Características de los sensores pasivos	41
2.6.1.1.1	Resolución Espacial.....	41
2.6.1.1.2	Resolución Espectral.....	42
2.6.1.1.3	Resolución Radiométrica	42
2.6.1.1.4	Resolución Temporal	42
2.6.2	Sensores activos	42
2.6.2.1	Fundamentos del RADAR	43
2.6.2.1.1.1	Resolución	43

2.6.2.1.1.2	Alcance	43
2.6.2.1.1.3	Azimut	44
2.6.2.1.2	Ángulo de incidencia	44
2.6.2.1.3	Frecuencia	45
2.6.2.2	Características de la imagen.....	45
2.6.2.2.1	Desplazamiento topográfico.....	45
2.6.2.2.2	Geometría de la formación de la imagen de RADAR.....	46
2.6.2.2.3	Polarización.....	46
2.6.2.3	Mecanismos de reflexión de las microondas.....	47
2.6.2.3.1	Reflexión difusa y especular	47
2.6.2.3.2	Reflexión de las microondas	47
2.6.2.3.3	Contenido de humedad	47
2.6.2.4	Interferencias	48
2.6.2.4.1	Ruido (<i>speckle</i>)	48
2.6.2.4.2	Clutter.....	48
2.6.2.4.3	Jamming.....	48
2.6.2.5	Clasificación de los sistemas de RADAR	49
2.6.2.5.1	RADAR de vista lateral (SLAR).....	49
2.6.2.5.2	Sistema RADAR de abertura real (RAR).....	49
2.6.2.5.3	Sistema RADAR de abertura sintética (SAR).....	49
2.7	PROGRAMA Sentinel	51
2.7.1	Sentinel-1	51
2.7.2	Sentinel-2	53
2.7.3	Sentinel-3	54
2.7.4	Sentinel-4, 5 y 6	54
2.8	PROGRAMA PERUSAT-1	55
2.9	PROGRAMA PLANET	57

2.10	PROCESAMIENTO DE IMÁGENES SATELITALES	57
2.10.1	Pre-Procesamiento.....	57
2.10.1.1	Correcciones radiométricas.....	58
2.10.1.2	Correcciones geométricas.....	58
2.10.1.3	Correcciones atmosféricas.....	59
2.10.1.4	Filtros Espaciales	59
2.10.1.5	Realces de imágenes satelitales.....	59
2.10.1.6	Índices.....	60
2.10.1.6.1	GRVI (índice de proporción verde).....	60
2.10.1.6.2	GI (índice de verdor)	60
2.10.1.6.3	SAT (Saturación – IHS).....	60
2.10.2	Procesamiento	61
2.10.2.1	Segmentación de imágenes satelitales	62
2.10.2.2	Clasificación de Imágenes	62
2.10.2.2.1	Clasificación Supervisada	62
2.10.2.2.1.1	Mínima Distancia.....	63
2.10.2.2.1.2	Paralelepípedos	63
2.10.2.2.1.3	Máxima Probabilidad o máxima verosimilitud	64
2.10.2.2.1.4	<i>Boosting</i> o árboles de decisión	65
2.10.2.2.1.5	<i>Support Vector Machine</i> (SVM).....	67
2.10.2.2.2	Clasificación No Supervisada.....	68
2.10.3	Post-Procesamiento	68
2.11	TASA DE ERROR DE CLASIFICACIÓN.....	69
2.12	VALIDACIÓN DE LOS MAPAS	69
2.12.1	Juicio de Expertos	70
2.12.2	Matriz de Confusión	71
2.12.3	Índice Kappa	72

3	MATERIALES Y MÉTODOS	73
3.1	DESCRIPCIÓN DEL ÁREA DE ESTUDIO	73
3.2	EQUIPOS Y MATERIALES	75
3.3	METODOLOGÍA	76
3.3.1	Selección de Imágenes	77
3.3.2	Pre-Procesamiento.....	77
3.3.3	Procesamiento	79
3.3.3.1	Modelo 1: Clasificación supervisada del cambio de uso de la tierra 2016 -2018	82
3.3.3.2	Modelo 2: Clasificación supervisada del Cambio de uso de la tierra 2015 -2019	82
3.3.3.3	Modelo 3: Clasificación supervisada del Cambio de uso de la tierra 2016 -2018	83
3.3.3.4	Modelo 4: Clasificación supervisada del Cambio de uso de la tierra 2015 -2019	83
3.3.4	Post-Procesamiento	84
3.3.5	Análisis Estadístico	85
3.3.6	Validación del mapa	86
4	RESULTADOS Y DISCUSIONES.....	88
4.1.1	Imágenes seleccionadas.....	88
4.1.2	Pre-Procesamiento.....	88
4.1.3	Procesamiento	91
4.1.3.1	Clasificación	94
4.1.3.1.1	Modelo 1	94
4.1.3.1.2	Modelo 2	98
4.1.3.1.3	Modelo 3	103
4.1.3.1.4	Modelo 4	105

4.1.4	Post-Procesamiento	109
4.1.5	Análisis Estadístico	109
4.1.5.1	Resultado del Modelo 1	109
4.1.5.2	Resultado del Modelo 2.....	110
4.1.5.3	Resultado del Modelo 3.....	112
4.1.5.4	Resultado del Modelo 4.....	113
4.1.6	Validación del Mapa	114
4.1.6.1	Puntos de validación	117
4.1.6.2	Matriz de confusión	123
5	CONCLUSIONES Y RECOMENDACIONES	126
	REFERENCIAS BIBLIOGRÁFICAS	128
	ANEXO 1 – IMÁGENES SATELITALES PARA ANÁLISIS	137
	ANEXO 2 – ETAPAS PARA LA UNIÓN DE BANDAS SATELITALES (PCI GEOMÁTICA 2018)	138
	ANEXO 3 – ETAPAS DE LA GENERACIÓN DEL MOSAICO SATELITAL (PCI GEOMÁTICA 2018)	139
	ANEXO 4 – ETAPAS PARA LA GENERACIÓN DE SEGMENTOS (PCI GEOMÁTICA 2018)	140
	ANEXO 5 - CÁLCULO DE ATRIBUTOS (PCI-GEOMÁTICA 2018)	141
	ANEXO 6 - ÁREAS DE ENTRENAMIENTOS (PCI-GEOMÁTICA 2018)	141
	ANEXO 7 - CLASIFICACIÓN ALGORITMO SVM (PCI-GEOMÁTICA 2018)	142
	ANEXO 8 - ADECUACIÓN DE ÁREAS DE ENTRENAMIENTO ÁRBOLES DE DECISIÓN (ERDAS IMAGINE 9.2)	142
	ANEXO 9 - REGLAS DE SALIDA DE LA CLASIFICACIÓN (SEE 5 / C5)	143

ANEXO 10 - RESULTADO ARCHIVO *.names (SEE 5 / C5).....	143
ANEXO 11 - RESULTADO ARCHIVO *.tree (SEE 5 / C5).....	144
ANEXO 12 - CLASIFICACIÓN SUPERVISADA (ERDAS IMAGINE 9.2).....	144
ANEXO 13 – GENERACIÓN DE RED DE PUNTOS PARA VALIDAR	145
ANEXO 14 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 1	146
ANEXO 15 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 2	148
ANEXO 16 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 3	151
ANEXO 17 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 4	152
ANEXO 18 - VALIDACIÓN MOSAICO DE FOTOGRAFÍAS ÁEREAS (PIX4DMAPPER)	153

1 INTRODUCCIÓN

Según la OTCA (2014), en la Amazonía viven 420 diferentes pueblos indígenas y tribales que hablan 86 lenguas y 650 dialectos. Al menos 60 pueblos viven en condiciones totales de aislamiento. Los bosques tropicales son ecosistemas imprescindibles para la vida albergando millones de especies de plantas y animales, proveen de alimento y refugio, son reguladores del clima y del agua, previenen la erosión de los suelos, conservan la biodiversidad, protegen el agua y, mitigan los efectos de los cambios climáticos. La Amazonía peruana ocupa más de la mitad del territorio nacional. En estos bosques húmedos tropicales viven aproximadamente 60 etnias indígenas que dependen de estos bosques.

El Perú es considerado como uno de los 17 países megadiversos del planeta según Cordero (2011), ocupando el noveno puesto de los países con mayor área de bosque en el período 2010 - 2015, lo que representa el 2% del bosque mundial (FAO, 2012). Sin embargo, la deforestación y la degradación son las principales amenazas que afrontan estos bosques. El 80% de la deforestación ha tenido lugar sobre tierras de capacidad de uso mayor forestal o de protección; es decir, sobre tierras no aptas para actividades agropecuarias debido a la baja probabilidad de que estas actividades sean sostenibles por la pérdida de productividad de los suelos que conforme pasa el tiempo se empobrece y se erosiona (MINAM, 2014). Adicionalmente, el cambio del uso de la tierra modifica los intercambios de energía albedo de la superficie y de la atmósfera (FEARNSIDE; LAURANCE, 2004).

En el Perú se registra una pérdida acumulada de cobertura de bosques para los años 2001 – 2017 de 2 130 123 ha teniendo como año base el año 2000. El departamento de Ucayali muestra una pérdida acumulada para el mismo período de 358 483 ha (Geobosques, 2019) siendo el tercer departamento con mayor pérdida de cobertura de bosques en la Amazonía peruana.

Por otro lado, en las cifras oficiales de uso y cambio de uso de la tierra se registra la cuantificación en seis categorías para cuatro períodos: 2000 - 2005, 2005 - 2011, 2011 - 2013 y 2013 - 2016. No obstante, la fuente oficial de monitoreo de deforestación no muestra la metodología ni los protocolos utilizados para este

resultado (Geobosques, 2019).

En este sentido, el presente estudio de investigación propone un modelo de clasificación supervisada de imágenes de sensores remotos para determinar el cambio de uso de la tierra, en la zona amazónica peruana considerando la temporalidad del estudio con años muy cercanos entre ellos para luego comprarlos mediante técnicas de inteligencia artificial.

1.1 OBJETIVOS

Esta investigación tiene como objetivo general, proponer un modelo de clasificación supervisada de cambio de uso de la tierra empleando imágenes satelitales pasivas, activas o fusión de ellas para el distrito de Nueva Requena, provincia de Coronel Portillo Ucayali, Perú de los años 2016 – 2018 basado en la leyenda del Grupo Intergubernamental de expertos sobre cambio climático (IPCC).

Para atender al objetivo general, se establecieron los siguientes objetivos específicos:

- Definir la mejor imagen satelital pasiva, activa o fusión para el cambio de uso de la tierra, mediante de tasa de error de clasificación en el distrito de Nueva Requena.
- Aplicar diferentes insumos de las imágenes satelitales tales como bandas, índices (GI, GRVI y Saturación-IHS) y polarizaciones a través de tasa de error de clasificación para determinar el cambio de uso de la tierra en el distrito de Nueva Requena.
- Testear cuatro diferentes metodologías de clasificación supervisada a través de tasa de error de clasificación entre los algoritmos *Support Vector Machine* (SVM) y algoritmo *Boosting* o árboles de decisión en imágenes satelitales pasivas, activas o fusión para determinar el cambio de uso de la tierra en el distrito de Nueva Requena.
- Validar la pertinencia de clasificación supervisada con imágenes de alta resolución e información de campo del distrito de Nueva Requena.

1.2 HIPÓTESIS

La hipótesis probada es que el cambio de uso de la tierra testeada con la clasificación supervisada con diferentes algoritmos para el distrito de Nueva Requena, departamento de Ucayali Perú con una fuerza de concordancia de mayor a aceptable.

2 REVISIÓN DE LITERATURA

2.1 ASPECTOS CONCEPTUALES

2.1.1 Concepto de Bosque

Según el concepto de (FAO, 2012), los bosques son Tierras que se extienden por más de 0,5 ha, dotadas de árboles de una altura superior a 5 m y una cubierta de dosel superior al 10 por ciento, o de árboles capaces de alcanzar esta altura in situ. No incluye la tierra sometida a un uso predominantemente agrícola o urbano.

De acuerdo al Servicio Nacional Forestal y de Fauna Silvestre, SERFOR (2017) un bosque es un “ecosistema predominantemente arbóreo que debe tener una superficie mayor a 0,5 ha, con un ancho mínimo de 20 metros y presentar una cobertura de copas mínima del diez por ciento. La vegetación predominante está representada por árboles de consistencia leñosa que tienen una altura mínima de dos metros en su estado adulto para costa y sierra, y cinco metros para la selva amazónica. En su concepción integral, comprende el relieve, suelo, agua, plantas, fauna silvestre y los microorganismos que condicionan asociaciones florísticas, edáficas, topográficas y climáticas con capacidad funcional autosostenible para brindar bienes y servicios. En el caso del bosque denso está estructurado en varios estratos”.

Los bosques son recursos forestales que forman parte del patrimonio forestal y su manejo y aprovechamiento es normado por la autoridad nacional forestal y de fauna silvestre, SERFOR (2016). En el reglamento de dicha ley se indica el uso múltiple del bosque refiriéndose al aprovechamiento de diversas opciones de productos y servicios del bosque, que incluyen madera, productos diferentes a la madera, fauna silvestre como usos directos, pero también aquellos que se denominan de usos indirectos, como el disfrute del paisaje, u otros servicios que este proporciona, entre los cuales se puede incluir protección de biodiversidad, conservación de aguas y tierras, y captura de carbono. El otorgamiento de administración y control de los bosques lo realizan los Gobiernos Regionales (GORE) en los cuales el Estado ya haya transferido las competencias del sector forestal, y la supervisión del

cumplimiento de las normativas es realizada por el Organismo de Supervisión de los Recursos Forestales y de Fauna Silvestre (OSINFOR).

2.1.2 Bosque húmedo tropical

Los bosques húmedos amazónicos están distribuidos en el Perú en siete tipos de cobertura: aguajal, bosque húmedo de colina baja y lomada, bosque húmedo de colina alta, bosque húmedo de montaña, bosque húmedo de superficie plana inclinada, bosque húmedo de terraza alta, bosque húmedo de terraza baja y media (MINAM, 2014).


MINAM (2016) señala que los bosques en el Perú constituyen el ecosistema de mayor superficie, con 73 280 424 ha que representan el 57,3% del territorio nacional; dentro de estos bosques se encuentran los bosques húmedos amazónicos que cubren el 53,9% del país. FAO (2016) y SERFOR (2017) indican que la selva en el Perú ubicada en la zona oriental, posee una superficie aproximada de 77 762 019,29 ha y va desde los 100 hasta los 3800 m.s.n.m., con una cubierta vegetal en su mayoría arbórea y siempre verde. Esta región se subdivide en Ceja de Selva (por encima de los 2000 m.s.n.m.), Selva alta (entre los 500 y 2000 m.s.n.m.) y Selva baja (por debajo de los 500 m.s.n.m.).

Alguno de los beneficios de los bosques húmedos tropicales son los siguientes: estabilizan el clima y la atmosfera: por ser un importante almacén de carbono, factor clave en la absorción del dióxido de carbono (CO₂) y en la producción de oxígeno (O₂); regulan el ciclo hídrico y de la humedad; regulan las cuencas, aminoramiento de inundaciones y deslaves: el agua desciende más lentamente y puede ser aprovechada de mejor manera por los seres vivos; protección de suelos y control de sedimentación: reducen y controlan los procesos de erosión en zonas de alto poder pluvial y de sedimentación de los cuerpos de agua; fuente de productos forestales: productos maderables y no maderables que ofrecen potencialidad económica alta; fuente de productos de la vida silvestre; productos farmacéuticos y valor estético y turístico (PNUD, 2000).

Según Pulgar Vidal (1967), realiza una división sistemática del Perú con el criterio fundamental de la existencia de pisos altitudinales o pisos ecológicos, en función a las condiciones climáticas, relieve, flora, fauna y recursos naturales. Cada

piso altitudinal ha sido denominado utilizando términos de la sabiduría y cultura del antiguo hombre andino se tiene como antecedente al respecto en una obra de José de la Riva Agüero en 1918 (RIVERA, 2012) siendo estas los ocho regiones naturales del Perú comprendidas en la gran división regional Costa: Chala. Sierra: Yunga, quechua, Suni, Puna, Jalca. Selva: Rupa-Rupa y Omagua. Estas regiones naturales del Perú se muestran en un corte transversal del relieve como se muestra en la FIGURA 1.

FIGURA 1 – OCHO REGIONES NATURALES DEL PERÚ



FUENTE: Pulgar Vidal, J. (1967).

2.2 DEFORESTACIÓN

La Convención de las Naciones Unidas Contra la Corrupción, CNUCC, (2002) define deforestación como “la conversión por actividad humana directa de tierras boscosas en tierras no forestales”.

La definición de deforestación por parte del Estado peruano es la eliminación de la cobertura forestal de un bosque natural por causa del ser humano o de la naturaleza (Reglamento para la Gestión Forestal de la Ley N° 29763, Decreto Supremo 018-2015-MINAGRI).

La deforestación es la mayor actividad que origina emisión de gases de efecto invernadero; por esta actividad se pierden grandes extensiones de biomasa

arbórea, lo que coloca en peligro a la biodiversidad acompañante, no sólo por pérdidas de individuos arbóreos sino también por pérdida de refugios para la fauna silvestre y de servicios ambientales del bosque (LAURANCE; LAURANCE, & DELAMONICA, 1998)

MINAM (2014) refiere que la pérdida de bosques húmedos amazónicos en Perú se debe principalmente a la conversión del bosque en áreas agrícolas. Así en la primera versión de uso de la tierra en la Amazonía año 2011 se reporta la siguiente cobertura: áreas agrícolas con 32,8%, áreas artificializadas con 0,2%, vegetación secundaria con 38,4%, pastizales y herbazales con 24,3%, áreas mineras con 3,6%, suelos desnudos con 0,4%, otras tierras 0,4%.

La extracción de madera y la expansión de la infraestructura son las principales causas inmediatas identificadas. Entre los principales factores subyacentes se identifican: los factores demográficos, económicos, tecnológicos, políticos-institucionales y culturales o socio-políticos (LAMBIN et al., 2001).

2.2.1 Expansión agropecuaria

Estudios en la Amazonia de América del Sur indican que es afectada por varios factores, como el uso no adecuado y la degradación de recursos biológicos mediante la cacería, el tráfico ilegal de especies, la tala de árboles, etc. Las principales causas de la deforestación son la expansión de la frontera agrícola, la ganadería, la tala ilegal, la explotación de recursos no renovables (como petróleo), la construcción de carreteras, la colonización, entre otros. Otros problemas resultan del cambio en el uso de suelo, la creación de vías de acceso, los proyectos de desarrollo y la expansión de la frontera agrícola (MARTINEZ-VALLE et al., 2015).

En diferentes valles del oriente del Perú realizan cultivos bajo riesgo con uso de maquinarias desde la década de los 60 y 70 siendo el cambio de la cobertura por cultivo de arroz, plantaciones aceiteras. En laderas y colinas cultivos de café, piña, té, coca, naranja, papaya, paltos entre otros (IGN, 1989). Por otro lado, la mayoría de áreas de la Amazonía, la expansión agropecuaria ha sido desordenada y se ha realizado en tierras de vocación forestal y/o protección, por lo que las prácticas de agricultura migratoria se intensifican principalmente por la baja capacidad productiva de los suelos, dando origen a una gran cantidad de bosques

secundarios y tierras degradadas. Las tendencias actuales de expansión agrícola y ganadera, el fuego, la sequía y la tala podrían deforestar o severamente dañar el 55% del bosque húmedo amazónico para el año 2030 (MINAM. 2014).

2.2.2 Expansión urbana

Desde los años 1940, con la construcción y mejoramiento de las carreteras de penetración a Pucallpa y a la Selva Central, la Amazonía ha sido una zona de expansión de colonos provenientes de las montañas andinas, principalmente, abriendo las trochas y la vasta llanura a nuevos asentamientos humanos. En 1943 se crea el Ministerio de Agricultura considerando en su estructura a la “Dirección de Asuntos Orientales, Colonización y Terrenos de Oriente” (MINAM. 2014).

En el Perú, la brecha de lo rural y lo urbano es amplia, el nivel de pobreza en la zona rural llega al 60%, mientras en la zona urbana es de 23.5%; la pobreza extrema en la zona rural alcanza el 21% mientras que en las zonas urbanas es de 3.5%. Las estadísticas de empleo confirman las desigualdades regionales: en las áreas urbanas el 80% de la población económicamente activa (PEA) está empleada, mientras que en las áreas rurales solo el 20% tiene empleo formal (HOFFMAN Y GRIGERA, 2013).

Se reconoce que, tanto a nivel urbano como rural, entre regiones naturales y entre departamentos, existen diversas dinámicas condicionantes de atracción y expulsión de población migrante, y que ellos acarrearán procesos desencadenantes de orden social, económico y ambiental (Estrategia Nacional sobre Bosques y Cambio Climático, 2016).

2.2.3 Perturbación

La perturbación puede ser originado o causado naturalmente por fenómenos atmosféricos, geológicos, por fauna, etc.; o bien por el hombre como actor principal, estas perturbaciones ocupan la mayor superficie que las naturales tener implicaciones más importantes sobre el uso de la tierra, el desarrollo rural y conservación de los recursos naturales en general (SMITH, J. et al., 1997).

En el Perú se ha estimado que los peruanos hemos perdido aproximadamente 7, 9 millones de hectáreas de bosques primarios amazónicos, al año 2009. Asimismo, se sientan así las bases para un Sistema de Monitoreo de la Cobertura de la Tierra, Deforestación y Degradación Forestal, que es muy necesario y urgente para la gestión de los bosques peruanos” (MINAM & MINAGRI, 2012).

Como consecuencia del cambio climático global, se prevé un aumento en la frecuencia y severidad de fenómenos como heladas, sequías o incendios, lo cual exacerbará las condiciones de vulnerabilidad (reincidencia a la pobreza, reducción de la base productiva, por ejemplo). Entre los cambios previsibles se espera aumento de la mortalidad de los árboles e incremento de la frecuencia de los incendios forestales en la Amazonía, degradación del bosque fluvial y recesión, más allá de las tendencias existentes. Sumado a las perturbaciones actuales, que en su mayoría son humanas, están las perturbaciones por eventos extremos como tormentas y por cambios graduales en patrones de lluvias o temperaturas (Estrategia Nacional sobre Bosques y Cambio Climático, 2016).

2.3 EFECTOS DE LA DEFORESTACIÓN

La deforestación y degradación son las principales amenazas que afrontan los bosques húmedos amazónicos peruanos. Más del 80% de la deforestación ha tenido lugar sobre tierras de capacidad de uso mayor forestal o incluso en tierras de protección, en las cuales la probabilidad de que las actividades agropecuarias sean sostenibles es muy baja: la productividad baja conforme el suelo se empobrece y se erosiona, lo cual resulta más oneroso que lo que produce y por tanto se abandona (MINAM, 2016).

Los problemas derivados del proceso de deforestación son cuantiosos: destrucción de la biodiversidad, destrucción de los ecosistemas, emisión del dióxido de carbono, desaparición de especies animales, pérdida de servicios ambientales, y, sobre todo, destrucción del ecosistema donde habitan grupos indígenas amazónicos, colonos, ganaderos y unidades empresariales (GÓMEZ DE LA TORRE, ANDA, & BEDOYA GARLAND, 2017).

De acuerdo al informe al trabajo de Barrena et al. (2014) mediante el primer Mapa Forestal del Perú en año 1975 se estimó una tasa de deforestación anual promedio de 100 000 ha/año. MINAM (2014), indica que la superficie deforestada acumulada para el período 1990 – 2000 representa el 9,25% de la superficie de los bosques húmedos amazónicos del país y el 5,58% del territorio nacional.

Información generada de manera conjunta por el MINAM a través del PNCBMCC, el MINAGRI a través de SERFOR y la Sala de Observación de la OTCA, utilizando la metodología desarrollada por la Universidad de Maryland, estimaron la pérdida acumulada de la cobertura de bosque a nivel nacional de 2 130 122 ha en el período 2001 - 2017 (Geobosque, 2019).

La Estrategia Nacional de Conservación de Bosques y Cambio (Decreto Supremo N°007-2016- MINAM) identificó tres causas directas de la deforestación en los bosques húmedos amazónicos del Perú: (i) la expansión agropecuaria: principal en términos de superficie; (ii) las actividades extractivas ilegales e informales: con tendencia creciente en algunas provincias y (iii) la ampliación de infraestructura de comunicación, energía e industrias extractivas, siendo la expansión agropecuaria la principal en términos de superficie afectada (TABLA 1). Las actividades de extracción forestal no son una causa directa de deforestación, aunque si de degradación. Las causas indirectas están conformadas por factores estructurales y de difícil localización, señalándose por sus orígenes y efectos a nivel nacional y regional, pudiéndose clasificar en los siguientes factores: demográficos, económicos, tecnológicos, políticos-institucionales, culturales (TABLA 2).

TABLA 1 - CAUSAS DIRECTAS DE LA DEFORESTACIÓN EN BOSQUES AMAZÓNICOS PERUANOS

Causas Directas			
Expansión agropecuaria (51,6%)		Actividades extractivas ilegales e informales	Expansión de infraestructura de comunicación e industrias extractivas (0,3%)
Agricultura de pequeña y mediana escala	Agricultura de gran escala	Minería ilegal (5,8%)	Carreteras, Hidroeléctricas e Hidrocarburos
Ganadería pequeña y gran escala (39,9%)	Cultivo de coca (2,3%)	Tala ilegal	

FUENTE: Estrategia Nacional sobre Bosques y Cambio Climático (2016).

TABLA 2 - CAUSAS INDIRECTAS DE LA DEFORESTACIÓN EN BOSQUES AMAZÓNICOS PERUANOS

Causas Indirectas	
Factores	Causas
Demográficos	Crecimiento poblacional
	Dinámica de la migración
Económicas	Pobreza
	Incremento del precio de productos agropecuarios
	Demanda Internacional de productos agropecuarios
	Producto Bruto Interno (PBI) y Valor Agregado bruto (VAB)
	Población Económicamente activa (PEA)
	Precio del Oro
Tecnológicos	Bajo rendimiento/rentabilidad/sostenibilidad de la producción
	Escasa asistencia técnica/tecnología inadecuadas
Políticos /Institucionales	Marco legal para titulación de tierras
	Tenencia de tierra
	Gobernanza forestal
Culturales	Nivel educativo/cultura ambiental
	Bajo conocimiento del uso de los recursos del bosque

FUENTE: Estrategia Nacional sobre Bosques y Cambio Climático (2016).

2.4 TÉCNICAS DE DETECCIÓN DE DATOS

2.4.1 Trabajos realizados de detección de Deforestación

El Brasil es uno de los países que viene trabajando más de treinta años con la detección de deforestación, el proyecto PRODES realiza un monitoreo satelital de la deforestación definida en la Amazonía Legal y produce, desde 1988, tasas anuales de deforestación en la región, que son utilizadas por el gobierno brasileño para establecer políticas públicas. Las tasas anuales se estiman en función de los incrementos de deforestación identificados en cada imagen de satélite que cubre la Amazonía Legal. Los datos consolidados se presentan en el primer semestre del año siguiente.

PRODES utiliza imágenes satelitales de la clase LANDSAT (20 a 30 metros de resolución espacial y velocidad de revisión de 16 días) en una combinación que busca minimizar el problema de la cobertura de nubes y asegurar criterios de interoperabilidad. Las imágenes del satélite estadounidense LANDSAT-5 / TM han sido históricamente las más utilizadas por el proyecto, pero las imágenes del sensor CCD a bordo del CBERS-2 / 2B, satélites del programa de teledetección sino-brasileño, se han utilizado ampliamente. PRODES también hizo uso de imágenes LISS-3 del satélite indio IRS-1 y también del satélite inglés UK-DMC2. Actualmente hace un uso masivo de las imágenes LANDSAT 8 / OLI, CBERS 4 e IRS-2. Sin importar el instrumento utilizado, el área mínima mapeada por PRODES es de 6.25 hectáreas.

Este sistema ha demostrado ser de gran importancia para las acciones y la planificación de políticas públicas en la Amazonía. Los resultados recientes, basados en análisis realizados por expertos independientes, indican un nivel de precisión cercano al 95%; la tasa anual de deforestación de PRODES se ha utilizado como indicador para proponer políticas públicas y para evaluar la efectividad de sus implementaciones. Todos los programas para monitorear los cambios en la cubierta forestal en el Amazonas, actualmente operado por INPE, utilizan el sistema de información geográfica llamado TerraAmazon . Este sistema se basa en la biblioteca de clases y funciones del sistema de información geográfica (SIG) para el desarrollo de aplicaciones geográficas desarrolladas por INPE y sus socios, llamado TerraLib . Esta biblioteca está disponible en Internet en forma de código abierto (código abierto) que permite un entorno de colaboración para el desarrollo de diversas herramientas SIG.

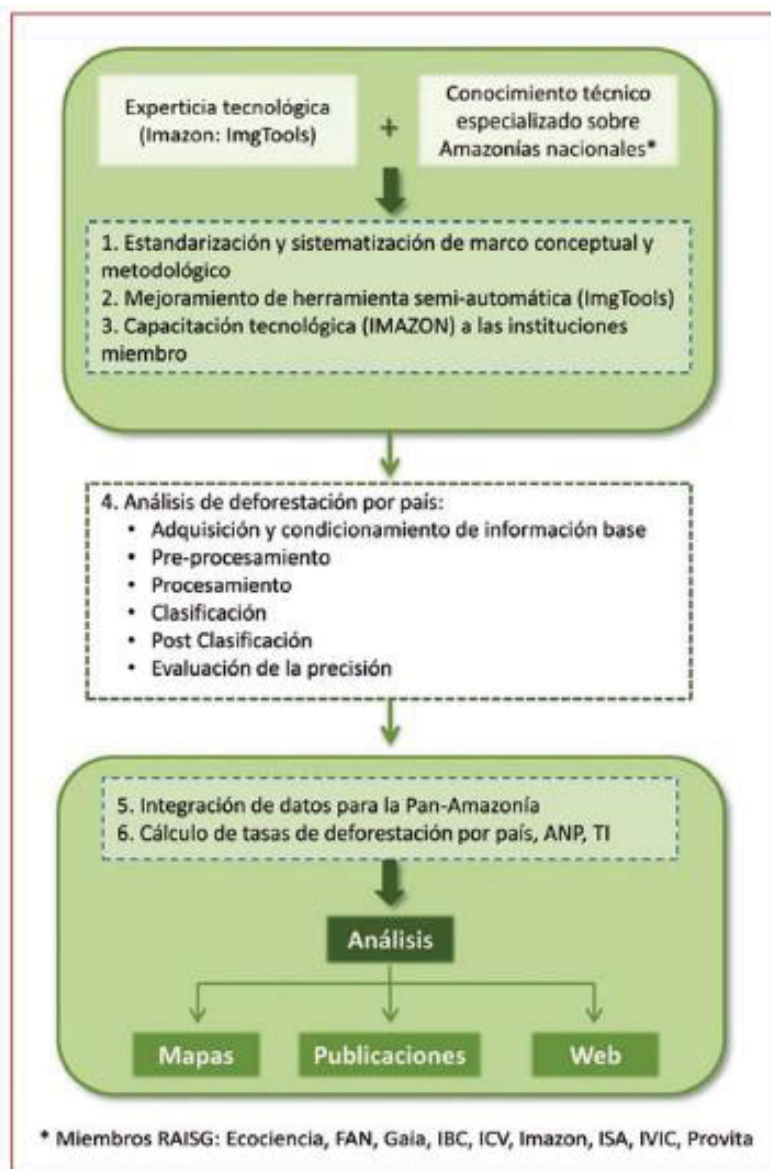
El proyecto PRODES cuenta con la colaboración del Ministerio del Medio Ambiente (MMA) y el Instituto Brasileño del Medio Ambiente y Recursos Naturales Renovables (IBAMA) y es parte del Ministerio de Ciencia, Tecnología, Innovaciones y Comunicaciones (MCTIC) en el Grupo Trabajo interministerial permanente para reducir las tasas de deforestación en la Amazonía legal, creado por decreto presidencial del 3 de julio de 2005. El GTPI es parte del Plan de Acción para la Prevención y Control de la Deforestación en la Amazonía legal, lanzado el 15 de marzo de 2004. Además de los datos tabulares, los resultados de PRODES digitales también están disponibles para la comunidad brasileña en forma de mapas

vectoriales e imágenes de satélite utilizados, en un formato compatible con la mayoría de los sistemas de información geográfica del mercado (INPE, 2019)

Otro análisis de deforestación en la región Amazónica es con el protocolo RAISG (Red Amazónica de información Socioambiental georreferenciada) que se basa en la integración y sinergia entre el conocimiento y capacidades de las instituciones miembro de la Red. Se desarrolló herramientas computacionales para el procesamiento y análisis de la deforestación, fue proporcionado por Imazon (Instituto do Homem e Meio Ambiente da Amazônia). Se utiliza una metodología consolidada y herramientas que han sido probadas y aplicadas en la Amazonía brasileira, utilizando varios sensores remotos (CBERS, MODIS, SPOT 5 MS, Aster, Landsat 5/TM, 7/ETM+, 8) 4 y en el ámbito de la Pan-Amazonía⁵. En el marco de esta publicación estamos presentando un análisis de deforestación multitemporal que considera los periodos 2000 – 2005, 2005 – 2010 y 2010-2013, donde el año 2000 constituye la línea base para toda la Amazonía. Los procedimientos específicos de ambos procesos se indican en las secciones Deforestación: secciones subsiguientes, Deforestación contemporánea.

La adquisición de imágenes satelitales: se utilizaron imágenes de satélite Landsat 5/TM, 7/ETM+ y 8, idealmente con una cobertura de nubes menor a 20%. Las imágenes tienen una resolución espacial de 30 metros para las bandas requeridas cubren un área aproximada de 180 km x 180 km. Fueron adquiridas vía Web de la Universidad de and Science Center (EROS) (<http://glovis.usgs.gov>) y United StatesMaryland (<http://www.glcg.uniacs.umd.edu>), el Instituto de Pesquisas Espaciales (INPE) (<http://www.inpe.br>), Earth Resources Observation and Geological Survey (<http://earthexplorer.usgs.gov>). Aproximadamente 294 imágenes Landsat cubren la región Amazónica. El año 2000 fue definido como línea base y los años 2005, 2010 y 2013 como puntos de corte para el análisis. En la FIGURA 2 se observa el protocolo RAISG. (RAISG, 2015).

FIGURA 2 – PROTOCOLO RAISG PARA EL ANÁLISIS DE LA DEFORESTACIÓN EN LA PAN-AMAZONÍA



FUENTE: RAISGS (2019).

Un ejemplo de América del norte es un estudio de análisis de deforestación en las montañas de México según Pompa, M. (2008), se realizó en cuatro zonas de montañas en el Noroeste de México, mediante las bases de datos digitales a partir de imágenes MODIS sobre ellas, se obtuvieron los valores del NDVI, que calcula la cantidad de vegetación presente en una superficie y se estima mediante la relación de la reflectancia medida en las bandas infrarrojas cercana y la banda roja del espectro electromagnético, para determinar dónde han ocurrido posibles cambios en la cobertura vegetal; se hizo una interpretación visual de los polígonos o píxeles

en los cuales se detectó una disminución del índice y se asignó una leyenda; el área mínima cartografiable reportada fue de siete has. Las imágenes que se analizaron son de la época seca (enero a mayo de cada año) se realizó la corrección geométrica, buscando un error estándar en los modelos de ajuste menores a un pixel; se realizó una corrección por curvatura de la tierra, eliminando áreas en los extremos de la imagen; también se eliminaron las nubes y sombras mediante la separación de clúster usando bandas uno y siete y máscara en regiones de sombras. Finalmente, se estimó el valor radiométrico promedio mensual de cada banda mediante la conversión a ocho bits, usando una tabla de tipo ecualización, donde se representa el 99.5% de la radiometría de la imagen, perdiendo aquellos valores que tienen una frecuencia de representación menor al 0.5%. Posteriormente, se realizaron reconocimientos de campo para determinar y discutir las causas de la deforestación, tanto naturales como antropogénicas.

Por último, el análisis de deforestación de comunidades nativas en el Perú y el análisis acumulada de deforestación en el distrito de Nueva Requena del departamento de Ucayali. Según Mendoza, R., & Giudice, R. (2015) en el Análisis de la pérdida de cobertura forestal en comunidades nativas de la Amazonía del Perú presenta una metodología en tres fases: Fase I: Recopilación de información generado por el Mapa de pérdida de los bosques húmedos amazónicos del Perú 2000 – 2011, en formato ráster, se utilizaron diferentes archivos en formato shapefile para sistematizar los principales atributos para el análisis. Fase II: Sistematización de información sobre los atributos “Bosque 2011” y “Pérdida de bosque 2000-2011”, a nivel de categorías territoriales con títulos habilitantes, usando los archivos espaciales en la sección anterior. Fase III: Presentación de hallazgos El análisis consistió en sistematizar información sobre la existencia de bosques remanentes al 2011 y la pérdida de bosques por categorías territoriales y nivel político departamental. Se generó un histograma con los datos del promedio anual de pérdida de cobertura forestal de cada una de las comunidades, utilizando rangos de cinco en cinco hectáreas por año hasta 100 y luego una sola categoría mayor a este promedio dentro de las comunidades y se graficó la curva de Lorenz y se calculó el coeficiente de Gini para tener la distribución del promedio de pérdida de cobertura forestal en las comunidades.

KENÉ (2017) realizó un análisis Bosque - No Bosque en el distrito de Nueva Requena (Ucayali), utilizando diversas metodologías: imágenes Landsat 5 para los años 2006 y 2010 con combinación de bandas de 5,4,3; y Landsat 8 con la combinación de bandas 6,5,4 para el año 2015. Las imágenes se obtuvieron del Instituto Nacional de Pesquisas Espaciales de Brasil (www.inpe.br), INPE (2018)a: Imágenes Path / Row 006_066 007_066 de agosto del 2006, julio 2010, agosto 2015 y setiembre 2015. Con estas imágenes se generó un mosaico con ambas imágenes para cada año de estudio y se realizó una clasificación supervisada de imágenes de satélites con árboles de decisión, metodología usada en el Laboratorio de Teledetección Aplicada y SIG de la Facultad de Ciencias Forestales de la Universidad Nacional Agraria La Molina (FCF-UNALM).

2.5 CAMBIO DE USO DE LA TIERRA

Los procesos de cambio en la cubierta vegetal y uso de la tierra ocurren en una dinámica compleja asociada a múltiples variables como son el tipo de cubierta vegetal, las interacciones ecológicas, el ambiente físico, las actividades socioeconómicas y el contexto social (DALE & BEYELER, 2001).

La cobertura del suelo comprende los aspectos que recubren la superficie terrestre de origen natural o cultural, que son observables y pueden ser medidos utilizando fotografías aéreas o sensores remotos. El uso de suelo puede definirse como las funciones que se desarrollan sobre aquella cubierta, con el objetivo de modificarla o preservarla para obtener un beneficio, como por ejemplo la agricultura (PEÑA, 2007).

Los cambios en el uso de la tierra tienen un origen multifactorial. Deben ser analizados en distintas escalas temporales y espaciales que permitan conocer de manera espacial y a través del tiempo los cambios ocurridos en las coberturas (GEIST; LAMBIN, 2002).

Entender el efecto de las interacciones entre las causas que inducen el cambio de uso del suelo (procesos de decisión humana) y la cobertura boscosa (patrones de distribución espacial), es considerado clave para analizar las consecuencias sobre la biodiversidad y pronosticar cambios futuros (HAINES-YOUNG, 2009).

La normativa sobre cambio de uso actual de la tierra ha sido modificada con la entrada en vigencia de la Ley 29763, Ley Forestal y de Fauna Silvestre, y su Reglamento para la Gestión Forestal, aprobado mediante Decreto Supremo 018-2015-MINAGRI. Aquí se destaca la prohibición del cambio de uso actual en tierras de capacidad de uso mayor forestal y de protección a fines agropecuarios (MINAGRI, 2016).

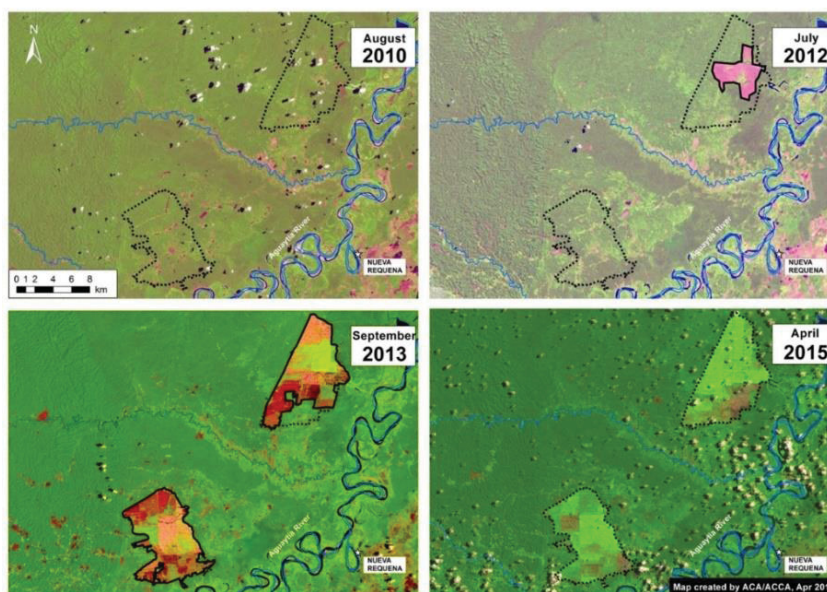
No obstante, a la normativa nacional vigente, la deforestación y el cambio de uso de la tierra continúan y en la última década la pérdida de bosques ha ido en aumento, no solo por la agricultura a pequeña escala, sino también, por el aumento de la agricultura a gran escala.

En ciertas regiones de la Amazonía la agricultura a gran escala se destina a la producción de biocombustibles, expandiéndose de forma muy extensa y visible. La agricultura migratoria sigue muy vigente entre unidades familiares de agricultores y ganaderos, particularmente migrantes o colonos, no solo en diversas regiones tropicales de América Latina, sino también en África y en Asia (BRONDIZIO, 2009; PERZ, 2002).

El cambio de uso de la tierra migrando de la cobertura de bosque a cultivos tales como palma aceitera y cacao en las regiones de Ucayali vienen provocando: (i) pérdida del patrimonio forestal y de fauna silvestre como producto de la deforestación; (ii) contaminación ambiental por un manejo inadecuado de los insumos químicos utilizados para la producción de dichos cultivos; y, (iii) situaciones de conflictividad en torno a la posesión y propiedad de predios privados y territorios indígenas (DEFENSORÍA DEL PUEBLO, 2019).

El Proyecto de Monitoreo de los Andes Amazónicos (MAAP) 2015 muestra la serie temporal del cambio de cobertura mediante sensores pasivos de mediana resolución, utilizando imágenes Landsat para los años 2010 – 2015 (FIGURA 3), donde se muestra el cambio de cobertura de bosque a uso como los cultivos de palma aceitera a gran escala.

FIGURA 3 - SERIE TEMPORAL LANDSAT 2010 – 2015



FUENTE: MAAP (2015).

La Defensoría del Pueblo (2019) indica que, entre el 2010 y 2014 en el distrito de Nueva Requena se deforestó 10 162,57 ha para la instalación de cultivos agroindustriales de palma aceitera y cacao y, en los años 2014 – 2015, se deforestó 6 824,89 ha para la instalación de plantaciones agroindustriales.

2.6 TELEDETECCIÓN

La teledetección es la técnica que permite adquirir imágenes de la superficie terrestre desde sensores instalados en plataformas espaciales, suponiendo que entre la tierra y el sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial, ya por emisión propia (CHUVIECO, 1990).

También es un medio para la protección del medio ambiente y de los recursos naturales, estando reconocida a nivel público y político. Esta valoración se debe a que, con el uso de sensores remotos, se puede disponer rápidamente de información sobre el estado y la evolución del medio ambiente (MEHL, H.; MIES, 1997).

2.6.1 Sensores pasivos

Según Hernández Pardo (2009), una imagen de satélite de cualquier sensor o sistema satelital presenta cuatro elementos básicos definidos bajo el concepto de resolución, la cual se puede clasificar en cuatro tipos: resolución espacial, resolución espectral, resolución radiométrica y resolución temporal. Los sensores de fuentes pasivas o también llamados ópticos obtienen la fuente de energía del sol y reciben en los satélites una medida relativa de la reflectancia de los diferentes elementos.

También las fotografías aéreas y digitales son sensores pasivos, ofreciendo la interpretación más exacta de lo que ve el ojo humano, en términos de respuesta a la longitud de onda, resolución, perspectiva, visión estereoscópica y valores tonales y de color. Las fotografías aéreas utilizando un sistema de percepción remota que utiliza la reflexión natural del sol, presentan variaciones de tono, textura, forma y patrones que corresponden a diferencias en rasgos y estructuras en la superficie. Las fotografías digitales son matrices bidimensionales en la que cada unidad mínima de información es el pixel con coordenadas filas y columnas y con un valor digital analizados en estaciones fotogramétricas por ordenador (SÁNCHEZ, 2009).

2.6.1.1 Características de los sensores pasivos

2.6.1.1.1 Resolución Espacial

La resolución espacial hace referencia al campo de visión, implicando al objeto más pequeño que se puede distinguir en la imagen, compuesto por píxeles los cuales son la unidad más pequeña identificable. Comúnmente representan una parte de la superficie en observación; en un sistema fotográfico se mide como la mínima separación a la cual los objetos aparecen distintos y separados en la fotografía (RODRIGUEZ; ARREDONDO, 2005).

2.6.1.1.2 Resolución Espectral

La resolución espectral indica el número y anchura de bandas espectrales identificables por el sensor remoto, se refiere al número, ancho y espaciamiento de las longitudes de onda a lo largo del espectro electromagnético que el sensor remoto es capaz de identificar. Los que poseen un mayor número de bandas presentarán mayor resolución espectral, como en los sensores hiperespectrales, por detectar una cantidad considerable de bandas espectrales (RODRIGUEZ; ARREDONDO, 2005).

2.6.1.1.3 Resolución Radiométrica

La resolución radiométrica se presenta como la capacidad para detectar las variaciones de radiancia espectral. El número máximo de niveles digitales de la imagen suele identificarse con la resolución radiométrica del sensor y esta se indica por el número de niveles de gris captados. Así mismo cada píxel de la imagen viene definido como un número entero; ese valor numérico se denomina nivel digital, que fácilmente puede ser traducido en la escala de grises mediante cualquier convertidor digital analógico. En cuanto mayor sea la resolución radiométrica, mejor podrá interpretarse la imagen (RODRIGUEZ; ARREDONDO, 2005).

2.6.1.1.4 Resolución Temporal

La resolución temporal se refiere al período de tiempo que un mismo sensor puede registrar información del mismo punto o lugar. Consiste en el período de tiempo necesario del satélite para contar con la posibilidad de recopilar los datos de una misma área. Puede ser diaria, semanal, mensual, etc. (HERNÁNDEZ PARDO, 2009).

2.6.2 Sensores activos

Lira (2010), define que los sensores activos son sistemas activos que controlan su propia fuente de iluminación permitiendo la adquisición de imágenes

a cualquier hora. La longitud de onda empleada en la región de microondas hace factible el estudio de la superficie terrestre en cualquier condición atmosférica.

Hernández Pardo (2009) indica que los RADAR es son sensores de fuentes activas o también conocidos como *Radio Detection And Ranging* (RADAR), emiten su energía artificialmente sobre plataformas aeroportadas o satelitales y reciben una señal de ondas electromagnéticas denominado coeficiente de retrodispersión o retrodifusión.

2.6.2.1 Fundamentos del RADAR

2.6.2.1.1.1 Resolución

Según el Centro Canadiense de Percepción Remota (2005), la resolución de los Radares tiene dos dimensiones: una en la dirección del alcance y otra en el azimut.

2.6.2.1.1.2 Alcance

Alcance es la resolución determinada por las características del RADAR y las del procesador a lo largo de la trayectoria entre el sensor y la superficie iluminada. La resolución en la dirección del alcance depende de la longitud del pulso transmitido; un pulso corto proporciona mejor resolución. La señal del RADAR se graba en el dominio del alcance; esta señal en forma digital se proyecta al plano del terreno al procesar la imagen. Los procesamientos asociados al alcance son: distancia a lo largo de la línea de vista entre el RADAR y en la región iluminada; dirección del alcance, que es perpendicular a la dirección de vuelo o azimut del sensor; resolución en la dirección del alcance, que es una característica de la imagen determinada por el ancho de banda del sistema o la duración efectiva del pulso.

2.6.2.1.1.3 Azimut

En un RADAR convencional, la resolución en la dirección del azimut se determina por el ancho angular del haz para poder identificar dos objetos independientemente.

El *Synthetic Aperture RADAR* (SAR) sintetiza una antena (virtual) muy grande al grabar la fase de las señales de microondas que recibe y mediante un procesamiento adecuado, se adquiere una resolución del azimut que depende del largo de esta antena sintética y es inversamente proporcional al tamaño de la antena real.

Procesamientos del Azimut, se usa comúnmente para indicar la distancia lineal en la dirección paralela a la trayectoria de vuelo.

Dirección del azimut, paralela a la línea de vuelo también es llamada dirección longitudinal a la trayectoria.

Resolución en la dirección del Azimut es la resolución característica en la dirección del azimut, limitada por el ancho de banda Doppler del sistema.

Compresión en la dirección del Azimut: en el dominio de la señal SAR, los datos crudos se extienden en las direcciones del alcance y del azimut y deben ser comprimidos de manera coherente para asegurar alcanzar la resolución potencial del instrumento. La compresión en la dirección del azimut consiste en correlacionar coherentemente la señal recibida con la función réplica del azimut.

2.6.2.1.2 Ángulo de incidencia

El ángulo de incidencia se refiere al ángulo entre la dirección de iluminación del RADAR y la normal a la superficie de la tierra. Dependiendo de la altura del RADAR sobre la superficie de la tierra, el ángulo de incidencia cambia a lo largo de la dirección del alcance. Por lo tanto, la geometría de visualización de una misma imagen es diferente de punto a punto en la dirección del alcance. El ángulo de incidencia local toma en cuenta la inclinación local de la superficie iluminada y esta influye de forma determinante en la brillantez de la imagen, (CCRS, 2005).

2.6.2.1.3 Frecuencia

La frecuencia, es la cantidad de oscilaciones de un movimiento ondulatorio y vibratorio, calculado en una unidad temporal, llamándose Hertz al suceso que ocurre una vez por segundo. La frecuencia de ondas se obtiene de dividir la velocidad de la onda por su longitud. Los sistemas de RADAR con sus respectivas longitudes de onda y frecuencias. Las bandas de RADAR X, C, L y P son las más utilizadas en estudios de cobertura forestal y de estimación de carbono (PONZONI; KUPLICH, 2015) (TABLA 3).

TABLA 3 - BANDAS UTILIZADAS POR LOS SISTEMAS DE RADAR CON SUS RESPECTIVAS LONGITUDES DE ONDA Y FRECUENCIAS

Banda de RADAR	Longitud de ondas γ (cm)	Frecuencia – F (MHz)
P	136-77	220-390
UHF (<i>Ultra High Frequency</i>)	100-30	300-1.000
L	30-15	1.000-2.000
S	15-7,5	2.000-4.000
C	7,5-3,75	4.000-8.000
X	3,75-2,40	8.000-12.500
Ku	2,40-1,67	12.500-18.000
K	1,67-1,18	18.000-26.500
Ka	1,18-0,75	26.500-40.000

FUENTE: Ponzoni; Kuplich (2015), adaptado de Lewi y Henderson (1998).

2.6.2.2 Características de la imagen

2.6.2.2.1 Desplazamiento topográfico

El CCRS (2005) indica que la dirección de observación de los RADAR es al formar la imagen es oblicua (i.e. iluminación lateral). Existe la posibilidad de un desplazamiento unidireccional del relieve, similar al que se observa con la fotografía aérea. La distorsión del terreno en las imágenes de RADAR es perpendicular a la trayectoria del vuelo o del satélite, es decir que los objetos más altos se observan

desplazados hacia el sensor. La región de la superficie del terreno que no se ilumina por el RADAR se representa como sombra en la imagen.

Las sombras se presentan detrás de las cumbres, en la dirección del alcance. Las sombras también proporcionan información sobre la escena, tal como la altura de un objeto. Las sombras en las imágenes de RADAR son importantes en la interpretación del relieve del terreno.

2.6.2.2.2 Geometría de la formación de la imagen de RADAR

La localización en el terreno de un campo instantáneo de vista (CIV) está determinada en una imagen RADAR por la medida simultánea de rango y del corrimiento *doppler*. De la antena al terreno existe una colección de puntos con el mismo rango (círculos) pero diferente corrimiento *doppler*. Similarmente, existe una colección de puntos con el mismo corrimiento *doppler* pero diferente rango. Para localizar un CIV unívocamente, es necesario encontrar la intersección de las líneas de puntos de mismo rango (equidistancia) con aquellas líneas de mismo corrimiento *doppler* (isodoppler) (LIRA, 2010).

2.6.2.2.3 Polarización

La polarización es definida por la trayectoria del campo eléctrico en un plano, que puede ser lineal, circular o elíptico. El campo eléctrico de la señal que emite un RADAR es perpendicular a la dirección de propagación esta dirección determina la polarización de la onda. Las imágenes de RADAR proveen información acerca de la superficie, a través de polarizaciones, estas pueden ser horizontales, verticales, lineales o circulares, en función de la aplicación. Las polarizaciones pueden ser horizontales o iguales como HH o VV (debido a que la radiación transmitida y recibida tienen la misma polarización) o polaridades verticales o cruzada HV o VH (cuando se transmite la radiación en una polarización y se recibe en otra). (PONZONI; KUPLICH, 2015).

2.6.2.3 Mecanismos de reflexión de las microondas

2.6.2.3.1 Reflexión difusa y especular

Según el CCRS (2005) la rugosidad de la superficie del suelo influye en la reflexión de la energía de las microondas, lo que tiene como consecuencia la brillantez de las características que se observan en las imágenes de RADAR. Las superficies horizontales lisas reflejan casi toda la energía incidente en forma especular, en una dirección alejándose del RADAR. Las superficies especulares, como regiones de aguas, autopistas pavimentadas, aparecen oscuras en las imágenes de RADAR. Las microondas incidentes sobre una superficie rugosa se reflejan en muchas direcciones, esto se conoce como reflexión difusa o esparcimiento. Las superficies con vegetación causan reflexión difusa, y se presentan con tonos brillantes en las imágenes de RADAR.

2.6.2.3.2 Reflexión de las microondas

Un RADAR mide la componente de la energía de las microondas que regresa por la misma trayectoria del haz de iluminación incidente, después de reflejarse difusa o especularmente por la superficie bajo observación. Comúnmente, las superficies rugosas aparecen más brillantes en las imágenes de RADAR que las superficies lisas, aunque estén compuestas de los mismos materiales.

2.6.2.3.3 Contenido de humedad

La presencia de humedad aumenta la constante dieléctrica (número complejo) de un material. Esta constante influye en la capacidad del material para absorber, reflejar y transmitir la energía de las microondas.

El contenido de humedad de un material puede cambiar sus propiedades eléctricas, lo que afecta la forma en que un material aparece en la imagen de RADAR.

La reflectividad y en consecuencia la brillantez de la imagen de la mayoría de la vegetación natural y de las superficies naturales, aumenta con el contenido de humedad.

2.6.2.4 Interferencias

2.6.2.4.1 Ruido (*speckle*)

El ruido *speckle* es un patrón indeseado que es producido por la interferencia mutua de un conjunto de frentes de onda reflejadas de forma difusa por los elementos que componen el terreno, sobre el receptor o célula de resolución (RANEY, 1998).

2.6.2.4.2 Clutter

El *clutter* hace referencia a todas aquellas señales que recibe el RADAR. Pueden estar causados por objetos del entorno, el mar, precipitación, tormenta de arena, animales, turbulencias atmosféricas y otros efectos atmosféricos como reflexiones ionosféricas (GARCÍA, 2004).

2.6.2.4.3 Jamming

El *jamming* está considerado como una fuente activa de interferencias, ya que está originado fuera del sistema RADAR y en general se trata de señales sin relación alguna con este.

El *jamming* es muy problemático para los RADAR es, pues suele tratarse de señales de mayor potencia que los ecos de interés (hay que tener en cuenta que la señal de interés recorre un camino de ida y vuelta RADAR-objetivo-RADAR, mientras que la señal interferente realiza solo un camino de ida). Las fuentes de *jamming* intencionado pueden por tanto ser efectivas, emitiendo con mucha menos potencia que los RADAR es que quieren confundir. La interferencia puede llegar al RADAR a través de la línea de visión directa ("*Mainlobe Jamming*" o "*jamming* de

lóbulo principal") o por otros caminos ("*Sidelobe Jamming*" o "*jamming* de lóbulos secundarios o laterales") (GARCÍA, 2004).

2.6.2.5 Clasificación de los sistemas de RADAR

2.6.2.5.1 RADAR de vista lateral (SLAR)

Los SLAR-RAR (Radares de Vista Lateral de Abertura Real) fueron los primeros sistemas generadores de imágenes de la superficie terrestre mediante el uso de microondas, utilizados durante la II Guerra Mundial en plataformas aéreas para los bombardeos nocturnos. El SLAR (*Side Looking Airborne RADAR*) posee una antena que irradia lateralmente los albos con un haz de microondas, el cual es amplio verticalmente y estrecho horizontalmente. El barrido para la obtención de la imagen es producido por el movimiento de la aeronave durante el paso sobre el área a ser recubierta. Este sistema de RADAR presenta el inconveniente de que su resolución azimutal es directamente proporcional a la distancia entre la antena y el albo "iluminado", e inversamente proporcional a la longitud de onda de la antena utilizada para la "iluminación". De esta forma, para obtener una mejor resolución azimutal es preciso disminuir la distancia entre el RADAR y el albo o aumentar la longitud de la antena (Paulina et al., 2015).

2.6.2.5.2 Sistema RADAR de abertura real (RAR)


En el esquema RAR de generación de imagen, la resolución varía en función directa de la distancia de la plataforma al terreno y del tamaño de la antena RADAR. A un sistema operando con tales características se le llama RADAR de Apertura Real (RAR) (LIRA, 2010).

2.6.2.5.3 Sistema RADAR de abertura sintética (SAR)

Con el desarrollo del RADAR de Abertura Sintética (SAR: *Synthetic Aperture RADAR*) es posible lograr una mayor resolución sin la necesidad de una antena físicamente grande, mediante un complicado procesamiento electrónico de

la señal de RADAR. La resolución resultante, unida a las pequeñas escalas a las que se pueden obtener imágenes, hace que el RADAR sea más útil que la observación fotográfica cuando se trata de cubrir grandes extensiones. El SAR mantiene su alta resolución a grandes distancias en la dirección de su alcance y también mantiene su resolución azimutal. La resolución con el SAR es cercana a los 10 m en azimut y alcance (OAS, 2009) (FIGURA 4).

FIGURA 4 - APERTURA SINTÉTICA



FUENTE: GLOBAL SAR (2012).

En la Tabla 4 se muestran las características de los sistemas de RADAR de apertura sintética (SAR).

TABLA 4 - CARACTERÍSTICAS DE LOS SISTEMAS DE RADAR DE APERTURA
SINTÉTICA(SAR)

Satélite / Sensor	Lanzamiento	Banda	Polarización	Resolución espacial (m)
Seasat/SAR	1978	L	HH	25
Shuttle/SIR-A	1978	L	HH	40
Shuttle/SIR-B	1984	L	HH	17-58
Almaz-1/SAR	1991	S	HH	15-30
ERS-1/SAR	1991,1995	C	VV	30
Jers-1/SAR	1992	L	HH	18
Shuttle/SIR-C/XSAR	1994	C,L y X	Polarimétrico	15-45
RADARSat/SAR	1995	C	HH	8-100
Evisat/Asar	2002	C	Polarimétrico	30-100
Alos/Palsar	2006	L	Polarimétrico	10-100
Cosmo/SkyMed	2007, 2008 y 2010	X	Polarimétrico	1-100
RADARSat-2/SAR	2007	C	Polarimétrico	3-100
TerraSAR/SAR	2007	X	Polarimétrico	1-18
Kopsar-5/SAR	2013	X	Polarimétrico	1-20
Sentinel-1 A y 1B/SAR	2014 y 2016	C	Polarimétrico	5-40
Biomass	2020	P	Polarimétrico	50-200

FUENTE: Ponzoni; Kuplich (2015).

2.7 PROGRAMA Sentinel

Según la Agencia Espacial Europea, ESA (2019)a, hay una nueva familia de misiones llamada Centinelas, específicamente para las necesidades operativas del programa Copérnico. Cada misión de Sentinel se basa en una constelación de dos satélites para cumplir con los requisitos de revisión y cobertura, proporcionando conjuntos de datos sólidos para los Servicios de Copernicus.

Estas misiones llevan una gama de tecnologías, como RADAR e instrumentos de imágenes multiespectrales para monitoreo terrestre, oceánico y atmosférico.

2.7.1 Sentinel-1

El Sentinel-1 es una misión de imágenes de RADAR de órbita polar, para todo clima, día y noche para servicios terrestres y oceánicos. Sentinel-1A se lanzó el 3 de abril de 2014 y Sentinel-1B el 25 de abril de 2016. Ambos fueron puestos en órbita en un cohete Soyuz desde el puerto espacial de Europa en la Guayana Francesa.


Los parámetros clave de la misión son tiempo de revisión, cobertura, oportunidad combinada con banda de frecuencia, polarización, resolución y otros parámetros de calidad de imagen. El tiempo de revisión breve exige una selección de órbita adecuada y grandes anchos de franja. Las características de este sensor se observan en la Tabla 5. La Figura 5 es una muestra del producto de Sentinel-1.

TABLA 5 - CARACTERÍSTICAS DEL SENSOR Sentinel-1

Órbita	Casi polar síncrona al sol, ciclo de repetición de 12 días, duración del ciclo de 175 días.
Modos operativos	<ul style="list-style-type: none"> - <i>Stripmap</i> (SM): franja de 80 km, resolución de 5 m x 5 m, aspecto simple - Franja ancha interferométrica (IWS): franja de 240 km, resolución de 5 m x 20 m, aspecto simple - Franja extra ancha (EWS): 400 km de franja, de una sola mirada - Franja ancha interferométrica (IWS): franja de 240 km, resolución de 25 m x 80 m, 3 miradas - Onda (WM): 20 km x 20 km, resolución de 20 mx 5 m, aspecto simple
Polarización	polarización dual para todos los modos VV + VH o HH + HV
Sensibilidad	NESZ (Sigma Zero equivalente de ruido), $\sigma_0 = -25$ dB
Radiometría	<ul style="list-style-type: none"> - Estabilidad = 0.5 dB - Precisión = 1.0 dB
Relación de ambigüedad	DTAR (Relación de ambigüedad objetivo distribuida) = -25 dB

FUENTE: Sentinel, 2018.

FIGURA 5 - PRODUCTOS ADQUIRIDOS POR Sentinel-1



FUENTE: Sentinel (2018).

2.7.2 Sentinel-2

El Sentinel-2 es una misión de imágenes de alta resolución multiespectral de órbita polar para el monitoreo de la tierra para proporcionar, por ejemplo, imágenes de la vegetación, el suelo y la cubierta de agua, las vías navegables y las zonas costeras. Sentinel-2 también puede entregar información para servicios de emergencia. Sentinel-2A se lanzó el 23 de junio de 2015 y Sentinel-2B siguió el 7 de marzo de 2017. Sentinel-2 proporciona imágenes ópticas de alta resolución para servicios terrestres. Proporciona, por ejemplo, imágenes de vegetación, suelo y cobertura de agua, vías navegables y zonas costeras. Sentinel-2 también entrega información para servicios de emergencia. Las imágenes Sentinel-2 A tienen 13 bandas (TABLA 6).

TABLA 6 - BANDAS ESPECTRALES DEL SENSOR Sentinel-2^a

	Bandas del Sentinel- 2	Longitud central de onda (µm)	Resolución espacial
Banda 1	Coastal aerosol	0,443	60
Banda 2	Blue	0,490	10
Banda 3	Green	0,560	10
Banda 4	Red	0,665	10
Banda 5	Vegetation red edge	0,705	20
Banda 6	Vegetation red edge	0,740	20
Banda 7	Vegetation red edge	0,783	20
Banda 8	NIR	0,842	10
Banda 8A	Vegetation red edge	0,865	20
Banda 9	Water vapour	0,945	10
Banda 10	SWIR – Cirrus	1,375	60
Banda 11	SWIR	1,610	20
Banda 12	SWIR	2,190	20

FUENTE: Sentinel (2018).

2.7.3 Sentinel-3

ESA (2019)^b indica que el Sentinel-3 es una misión de varios instrumentos para medir la topografía de la superficie del mar, la temperatura de la superficie del mar y de la tierra, el color del océano y el color de la tierra con precisión y fiabilidad de alta gama. La misión apoyará los sistemas de pronóstico oceánico, así como el monitoreo ambiental y climático. Sentinel-3A se lanzó el 16 de febrero de 2016 y Sentinel-3B se unió a su gemelo. El precursor Sentinel-5, también conocido como Sentinel-5P, es el precursor de Sentinel-5 para proporcionar datos oportunos sobre una multitud de gases traza y aerosoles que afectan la calidad del aire y el clima. Se ha desarrollado para reducir las brechas de datos entre el satélite Envisat, en particular el instrumento Sciamachy, y el lanzamiento de Sentinel-5. Sentinel-5P fue puesto en órbita en un lanzador Rockot desde el cosmódromo de Plesetsk en el norte de Rusia el 13 de octubre de 2017.

2.7.4 Sentinel-4, 5 y 6

Sentinel-4 tiene una carga útil dedicada al monitoreo atmosférico que se embarcará en un satélite *Meteosat Third Generation-Sounder* (MTG-S) en órbita geoestacionaria.

Sentinel-5 tiene una carga útil que controlará la atmósfera desde la órbita polar a bordo de un satélite MetOp de segunda generación.

Sentinel-6 lleva un altímetro de RADAR para medir la altura global de la superficie del mar, principalmente para la oceanografía operacional y para estudios climáticos.

2.8 PROGRAMA PERUSAT-1

El satélite peruano PERUSAT-1 es un satélite de observación de la Tierra que posee la capacidad de capturar imágenes multiespectrales de alta resolución. Fue desarrollado por la empresa francesa *Airbus Defence and Space* (AIRBUS), a petición del Estado peruano, para aplicaciones militares y civiles dentro del ámbito del territorio peruano. La construcción del satélite fue encargada por el gobierno del Perú en el mes de abril del año 2014, lográndose cumplir la meta de tener operativo el sistema de captura de información del satélite en menos de dos años. La Figura 6 muestra una representación artística del satélite peruano PERUSAT-1 (MTC, 2017).

Desde el 15 de setiembre de 2016, PERUSAT-1 envía diariamente imágenes del territorio peruano y del mundo, programado desde el Centro Nacional de Operaciones de Imágenes Satelitales – CNOIS para cubrir las necesidades de los diversos usuarios del país. Se encuentra en una órbita baja, que cruza los polos, a 702.5 km de distancia de la tierra. El satélite se desplaza a una velocidad de 27 000 km/h a diferencia de los satélites en órbita GEO que se encuentran distantes de la tierra y orbitan de manera sincronizada con la rotación del planeta (CONIDA, 2016).


La Agencia Espacial del Perú (CONIDA) gestiona sus productos a partir de los requerimientos del gobierno en temas de monitoreo agroforestal, planificación urbana, control de cultivos ilegales, monitoreo de desastres y control de infraestructura vial. El satélite PERUSAT-1 está basado en la plataforma de la línea de satélites ASTROBUS-300 (desarrollada por AIRBUS), teniendo como pares más cercanos a los satélites de la línea ASTROBUS-S (menor tamaño) y ASTROBUS-500, utilizados por las Agencias Espaciales de distintos países para misiones de observación de la Tierra (TABLA 7) (FIGURA 6) (MTC, 2017).

TABLA 7 - CARACTERÍSTICAS DEL SENSOR PERÚSAT-1

Ítem	Detalle
Entidad responsable	CONIDA
Misión	Observación de la Tierra (óptica)
Órbita	Helio-síncrona (694 km)
Resolución espacial	0,7m en Pancromático, 2,8 m en el multiespectral
Dimensiones	1,0 m x 1,0 m x 1,7 m
Fecha de lanzamiento	16 de setiembre del 2016 (Kourou, Guyana Francesa)
Tiempo de vida de diseño	10 años
Ancho de barrido	14,5 km
Banda espectral	01 banda Pancromática: 0,45 – 0,75 μ m
Bandas espectrales	04 bandas multiespectrales: Blue: 0,45 – 0,52 μ m Green: 0,53 – 0,60 μ m Red: 0,62 – 0,69 μ m NIR: 0,76 – 0,89 μ m
Resolución radiométrica	12 bits
Programación	12 horas o 3 horas en caso de emergencia
Seguridad de la transmisión	Encriptado
Memoria a bordo	1 Tera bits
Masa de la cámara	60 kg
Tecnología	Carburo de silicio
Masa	400 kg al lanzamiento

FUENTE: CONIDA (2016).

FIGURA 6 - REPRESENTACIÓN ARTÍSTICA DEL SATÉLITE PERUANO



FUENTE: CONIDA (2016).

2.9 PROGRAMA PLANET

Según PLANET Labs (2019), la constelación de satélites PLANETScope consiste en múltiples lanzamientos de grupos de satélites individuales. La constelación completa de PLANETScope, de aproximadamente 130 satélites, puede obtener imágenes de toda la superficie terrestre todos los días (lo que equivale a una capacidad de recolección de 200 millones de km²/día) (TABLA 8).

TABLA 8 - CARACTERÍSTICAS DEL SENSOR PLANET

Ítem	Detalle
Órbita	Sincrónica al sol
Altitud	400 km, Inclinación 51,6 °
Altitud	475 km, Inclinación 98 °
Cobertura de latitud	± 52 °
Bandas espectrales	Azul: 455 - 515 nm Verde: 500 - 590 nm Rojo: 590 - 670 nm NIR: 780 - 860 nm
Distancia de muestreo del terreno (nadir)	3,0 m (aproximado) 3,7 m
Tamaño del marco	20 km x 12 km (aproximado) 24,6 km x 16,4 km (aproximado)
Capacidad de captura de imágenes Variable	200 millones de km ² / día

FUENTE: PLANET Labs (2016).

2.10 PROCESAMIENTO DE IMÁGENES SATELITALES

2.10.1 Pre-Procesamiento

Cualquier imagen adquirida por un sensor remoto, presenta una serie de alteraciones radiométricas y geométricas debidas a muy variados factores, en el caso concreto de las imágenes espaciales, las deformaciones más frecuentes pueden agruparse. Estas pueden ser defectos provenientes de la distorsión de la geometría particular que guarda la plataforma y el sensor con la escena y la fuente de iluminación, por condiciones atmosféricas, etc.

El pre-procesamiento tiene por finalidad eliminar cualquier anomalía detectada en la imagen, ya sea en su localización o radiometría de los píxeles que la componen (CHUVIECO, 2010).

2.10.1.1 Correcciones radiométricas

Las correcciones radiométricas consisten en la eliminación de distorsiones en la imagen debidas al sensor, el efecto de la topografía o el efecto de la atmósfera y la conversión de la energía registrada por el sensor a valores digitales (conversión analógica-digital). En los sensores modernos se realiza calibración de los detectores (energía medida versus energía reflejada o emitida por un cuerpo de referencia) para asegurarse que operen correctamente (SÁNCHEZ, 2012).

Estas correcciones buscan mejorar la precisión de las medidas de reflectancia, apuntan a eliminar ruidos en los niveles digitales de la imagen compensando las diferencias en los valores de radiancia y la conversión de los niveles digitales a valores de radiancia y reflectancia, utilizando modelos de atmósfera y las geometrías de iluminación/observación. El objetivo general es corregir los valores incorrectos recogidos por el sensor, siendo estos errores del sensor o introducidos en el proceso de almacenamiento o transmisión (CHUVIECO, 2010).

2.10.1.2 Correcciones geométricas

Olaya (2011) indica que las distorsiones de forma son provocadas por los movimientos y oscilaciones del sensor o por el relieve del terreno, entre otros factores.

Según Richards (2013), estos errores presentan habitualmente diversas formas de distorsión geométrica debido a los siguientes factores: la rotación de la tierra durante la toma de la imagen, la frecuencia de escaneo del sensor, la curvatura de la tierra, los efectos panorámicos, las variaciones en la velocidad y altura de la plataforma de registro.

Para disminuir estos efectos existen una serie de métodos cuya finalidad es corregir y distorsionar la imagen original con objeto de que esta constituya una representación más fiable de la escena original. Dos son los métodos más utilizados para la corrección geométrica de las imágenes: la rectificación y la ortorectificación. Los procedimientos matemáticos que resuelven este problema y las metodologías

usadas para su implementación, mediante algoritmos en las aplicaciones informáticas de teledetección son muy variados (BASTERRA, 2011).

2.10.1.3 Correcciones atmosféricas

El cálculo del valor de la reflectancia en superficie implica introducir algún tipo de corrección sobre el efecto que imprime la atmósfera sobre la señal recibida por el sensor. Los procedimientos para abordar las correcciones atmosféricas con exactitud son muy laboriosos y requieren datos sobre las condiciones de la atmósfera en el momento de tomar la imagen, que no suelen estar disponibles. Además, el efecto de la atmósfera no es constante en la imagen, algunas zonas pueden estar afectadas más que otras, en función de la diversa presencia de aerosoles o vapor de agua (CHUVIECO, 2010).

2.10.1.4 Filtros Espaciales

Según Sánchez (2012), los filtros espaciales tienen el objetivo de resaltar o suprimir un patrón espacial particular en la imagen basada en su frecuencia espacial (concepto relacionado con la textura de la imagen) o sea, la frecuencia de las variaciones en tonalidad en la imagen. Las áreas homogéneas tienen una baja frecuencia espacial y por tanto sus valores de brillantes son similares (baja variabilidad); en tanto que zonas con cambios abruptos en tonalidad tienen una frecuencia alta (alta variabilidad). Es común utilizar una ventana móvil de 3x3, 5x5 o 7x7 píxeles para realizar el filtrado. El procedimiento consiste en remplazar el valor central de la matriz de filtrado por un valor derivado de los valores de brillantes de los píxeles vecinos y de una operación matemática (promedio, moda, mediana).

2.10.1.5 Realces de imágenes satelitales

Según Olaya (2011), los realces son procedimientos que tienden a mejorar la interpretabilidad visual de una imagen satelital, pero no aumentan la cantidad de información contenida en ella. Las opciones que tiene el analista son ilimitadas, aunque se pueden agrupar en operaciones de punto (modifican el brillo de cada

pixel) y operaciones locales (modifican el valor de cada pixel basadas en el valor de los pixeles vecinos)

2.10.1.6 Índices

2.10.1.6.1 GRVI (índice de proporción verde)

El cálculo del GRVI se puede realizar en fotografías aéreas RGB. Debido a que el archivo no tiene metadatos disponibles, se trabaja con códigos adicionales del sensor. Este índice facilita el acceso a datos y las series de tiempo de procesamiento posterior. Se define como la relación normalizada entre el canal rojo y el verde de una imagen RGB. Sin embargo, se puede usar el canal azul y también un factor de ponderación (PCI-Geomática, 2018). Los valores positivos indican vegetación verde en distintos estados fenológicos.

2.10.1.6.2 GI (índice de verdor)

El índice GI indica el cociente entre la reflectividad en la banda del verde y la reflectividad en el infrarrojo cercano, detectando carotenos u otros pigmentos en parches de vegetación. Está relacionado al vigor del cultivo, cantidad de vegetación o biomasa (NAVARRO; HERNÁNDEZ, 2009).

2.10.1.6.3 SAT (Saturación – IHS)

El proceso IHS (intensidad, tono y saturación) convierte las bandas: rojo, verde y azul de la imagen, en canales de intensidad, tono y saturación. Es inverso al RGB. La realización de diferentes funciones de fusión de imágenes puede realizarse: fusionar las imágenes en color (RGB) con una imagen de intensidad en blanco y negro (B/N) dando como salida una deriva de la imagen RGB de entrada remuestreada; otro tipo de fusión son las imágenes (RGB) convierten los canales de imagen de intensidad, tono y saturación (IHS) esta transformación es utilizada para realizar la función de datos, esta función fusiona una imagen de pseudocolor con una imagen de intensidad en blanco y negro, el resultado es una imagen de

color RGB de salida con la misma resolución que la imagen de intensidad B/N original, pero donde el color (matriz y saturación) se deriva de la imagen de entrada muestreada nuevamente (PCI-Geomática,, 2018).

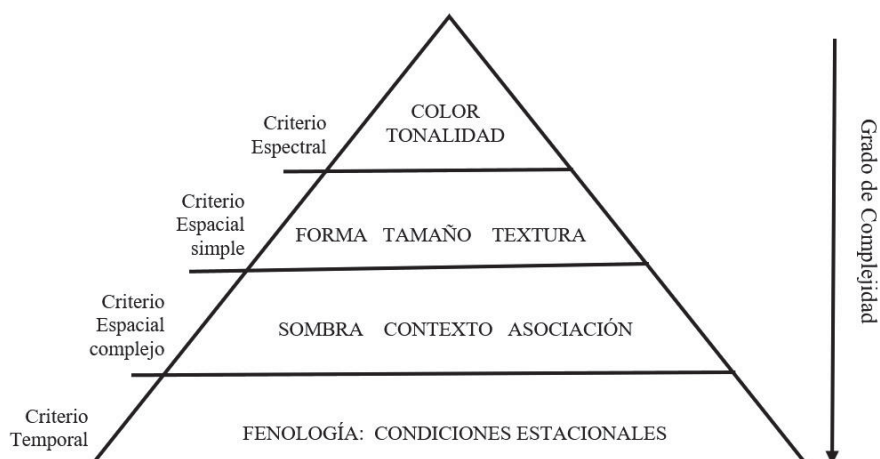
2.10.2 Procesamiento

Según ERDAS (2008), existen varios procedimientos para la clasificación de imágenes. La clasificación digital es el proceso de clasificar los píxeles de una imagen de satélite en un número finito de clases o categorías basado en los valores espectrales de cada píxel.

Los algoritmos de clasificación digital utilizan la reflectancia de cada píxel en diferentes longitudes de onda y un criterio estadístico para asignarlo a una clase espectral (bosque, pasto, urbano, etc.).

Según FAO (1999), para la clasificación de imágenes es necesario que el analista de las imágenes esté familiarizado con las características, detalles de la imagen y las particularidades de cada clase a recopilar mediante las áreas de entrenamiento de interés. El análisis visual puede, entonces, utilizar elementos como textura, estructura, emplazamiento o ubicación contextual, y otros factores de análisis que son posibles de aplicar en el tratamiento digital. Indica la complejidad de la interpretación en la medida que pasa a considerar elementos relacionados con la propia imagen a factores de análisis que depende del propio objeto en estudio y de las características ambientales en que se encuentra (FIGURA 7).

FIGURA 7 - CRITERIO DE VISUALIZACIÓN DE IMÁGENES



FUENTE: FAO (1999).

2.10.2.1 Segmentación de imágenes satelitales

Según PCI Geomática (2018), la segmentación es el cálculo de regiones discretas de objetos de la imagen, esto mediante la estratificación de la imagen. En teledetección se utiliza la segmentación para la identificación de atributos; el proceso divide una imagen en regiones u objetos estadísticamente homogéneos que son más uniformes dentro de sí mismos y difieren de sus vecinos adyacentes. No existe un algoritmo de segmentación único que pueda reproducir los mismos objetos que un humano. Los criterios que definen el crecimiento de una región pueden basarse en la diferencia entre la intensidad de píxeles y la media de la región. El algoritmo evalúa la homogeneidad local en función de las características espectrales y espaciales. El tamaño del segmento se controla con el valor de escala; cuanto mayor la escala, mayor el objeto de salida. Otro criterio de homogeneidad se basa en la forma y la compacidad dando como resultado una representación vectorial (polígono) de los objetos de la imagen.

2.10.2.2 Clasificación de Imágenes

2.10.2.2.1 Clasificación Supervisada

Basterra (2011) indica que en la clasificación supervisada el usuario selecciona en la imagen zonas representativas de la clase de información que desea utilizar en su clasificación (pasto, bosque, cultivo, etc.). Posteriormente el algoritmo de clasificación crea estadísticos para estas áreas y utiliza los resultados para clasificar el resto de la imagen. Se necesita de un cierto conocimiento de la zona de estudio, lo que permite al analista seleccionar áreas de entrenamiento, que son la base para que el programa a usarse pueda definir las clases deseadas, y luego asigne los píxeles de la imagen a las categorías establecidas. Este proceso presenta las siguientes etapas: entrenamiento, selección del algoritmo de clasificación, operaciones de post- clasificación.


En la etapa de entrenamiento el analista selecciona áreas de identidad conocida (clases previamente definidas) en polígonos sobre las imágenes cuyos valores quedan archivados como áreas de entrenamiento.

Luego es necesario definir un algoritmo para la clasificación:

2.10.2.2.1.1 Mínima Distancia

La Administración Nacional de la Aeronáutica y del Espacio, NASA (2016) afirma que la clasificación por mínima distancia se realiza mediante la asignación del valor del pixel más cercano calculando las distancias más cortas de los vectores espectrales en el espacio multidimensional, de acuerdo a la media de las clases de entrenamiento. Este clasificador no es muy apropiado cuando las clases espectrales están muy próximas entre sí en el espacio de medida y a la vez tienen elevadas varianzas (FIGURA 8).

FIGURA 8 - DISPERSIÓN DEL ALGORITMO DISTANCIAS MÍNIMAS




FUENTE: Angelini (2016).

2.10.2.2.1.2 Paralelepípedos

La clasificación por paralelepípedos permite al usuario unos umbrales de dispersión asociados a cada clase. Este clasificador define subespacios en forma

de paralelepípedo para cada clase. Los límites de cada paralelepípedo son definidos por el rango de valores para cada área de entrenamiento; el píxel de identidad desconocida debe caer dentro de alguno de los paralelepípedos para adjudicarlo a la correspondiente clase (BASTERRA, 2011). Es un clasificador fácil de implementar, pero está asociado a errores frecuentes de solapamiento de paralelepípedos (FIGURA 9).

FIGURA 9 - DISPERSIÓN DEL ALGORITMO PARALELEPÍPEDO




FUENTE: Angelini (2016).

2.10.2.2.1.3 Máxima Probabilidad o máxima verosimilitud

Según Basterra (2011), el algoritmo de máxima probabilidad o máxima verosimilitud es un algoritmo paramétrico que asume algunas distribuciones estadísticas particulares para las clases consideradas. El clasificador de máxima probabilidad es uno de los más empleados; utiliza un modelo probabilístico comúnmente la distribución gaussiana para formular sus reglas de decisión en la categorización de los píxeles. Los parámetros requeridos para este modelo son la mediana y la matriz de covariancia (de las áreas de entrenamiento) (FIGURA 10).

FIGURA 10 - DISPERSIÓN DEL ALGORITMO MÁXIMA PROBABILIDAD




FUENTE: Angelini (2016).

2.10.2.2.1.4 *Boosting* o árboles de decisión

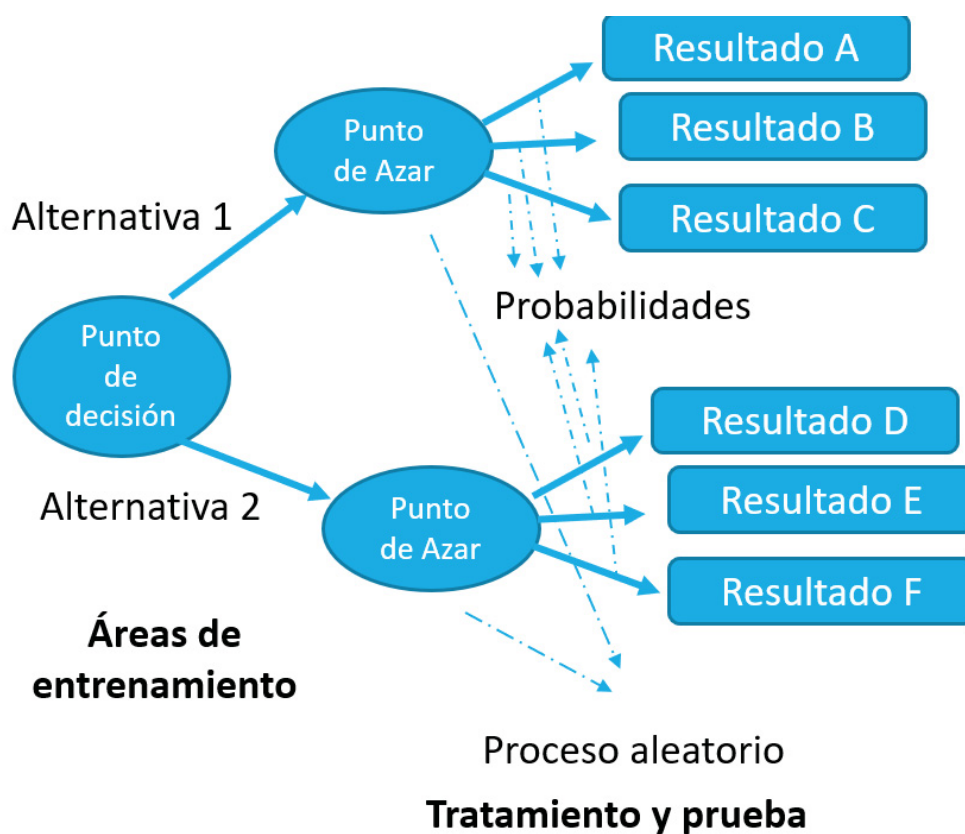
Según Franco et al. (2013) los árboles de decisión son algoritmos utilizados para resolver problemas de clasificación supervisada que se componen de nodos (internos y hojas) y de arcos. Sus nodos internos están caracterizados por uno o varios atributos de prueba y de estos nodos se desprenden uno o más arcos. Cada uno de estos arcos tiene asociado un valor del atributo de prueba y estos valores determinan qué camino seguir en el recorrido del árbol. Los nodos hoja contienen información que permite determinar la pertenencia del objeto a una clase. Según Rodríguez y Chica (2012), los árboles de decisión son una serie de métodos muy flexibles de regresión y de clasificación, que pueden manejar un gran número de variables, incluso con problemas de correlación entre ellas (FIGURA 11 y FIGURA 12).

FIGURA 11 - ESTRUCTURA DE UN ÁRBOL DE DECISIÓN



FUENTE: Rodríguez y Chica (2012).

FIGURA 12 - AREA DE ENTRENAMIENTO Y TRATAMIENTO EN ARBOLES DE DECISIÓN




FUENTE: La autora (2019).

2.10.2.2.1.5 Support Vector Machine (SVM)

El *Support Vector Machine* funciona correlacionando datos a un espacio de características de grandes dimensiones, de forma que los puntos de datos se puedan categorizar, incluso si los datos no se puedan separar linealmente de otro modo. Se detecta un separador entre las categorías y los datos se transforman de forma que el separador se puede extraer como un hiperplano. Tras ello, las características de los nuevos datos se pueden utilizar para predecir el grupo al que pertenece el nuevo registro.

La función matemática utilizada para la transformación se conoce como función *kernel*. Puede modelar algunos tipos de *kernel*: lineal, polinómico, función de base radial, sigmoide. Una función *kernel* lineal es recomendable si la separación lineal de los datos es sencilla. En otros casos, se debe utilizar una del resto de las funciones. Se deberá experimentar con las diferentes funciones para obtener el mejor modelo en cada caso, ya que utilizan algoritmos y parámetros diferentes (TABLA 9) (IBM, 2018). En la FIGURA 13 se muestra la estructura de *Support Vector Machine*.

FIGURA 13 – ESTRUCTURA DE *SUPPORT VECTOR MACHINE*



FUENTE: La autora (2019).

TABLA 9 - TIPOS DE *SUPPORT VECTOR MACHINE* (SVM)

Tipo de SVM	Kernel Mercer	Descripción
Función de base radial (RBF) o gaussiana	$K(x_1, x_2) = \exp\left(-\frac{\ x_1 - x_2\ ^2}{2\sigma^2}\right)$	Aprendizaje de una sola clase; σ es la anchura del kernel
Lineal	$K(x_1, x_2) = x_1^T x_2$	Aprendizaje de dos clases
Polinómica	$K(x_1, x_2) = (x_1^T x_2 + 1)^\rho$	ρ es el orden del polinomio
Sigmoid	$K(x_1, x_2) = \tanh(\beta_0 x_1^T x_2 + \beta_1)$	Es un kernel Mercer solo para determinados valores β_0 y β_1

FUENTE: MATLAB® (2015).

2.10.2.2.2 Clasificación No Supervisada

Los métodos no supervisados crean agrupamientos espectrales o *clusters* sin tener conocimiento previo del contenido de la imagen y el analista debe intentar asociar una clase temática a cada uno de dichos grupos. Uno de los algoritmos más conocidos es el Isodata. Estos algoritmos basan su efecto en la búsqueda de clases con suficiente separabilidad espectral para diferenciar los elementos (BASTERRA, 2011).

2.10.3 Post-Procesamiento

Según Basterra (2011), el análisis digital de datos es una serie de técnicas de manipulación numérica de datos contenidos en imágenes digitales, requiriéndose un software y hardware adecuados. El post-procesamiento digital de

imágenes es la aplicación de técnicas matemáticas, estadísticas y computacionales, que permiten mejorar, corregir, analizar y extraer información de las imágenes captadas por los sensores a bordo de los satélites.

2.11 TASA DE ERROR DE CLASIFICACIÓN

La tasa de errores de clasificación es generada de la matriz de confusión que usa como indicador las propiedades de una regla de clasificación (discriminante) y contiene el número de elementos que se han clasificado correctamente o incorrectamente para cada clase. Para cada instancia en el conjunto de prueba se comparan las clases actuales con las clases asignadas por el clasificador entrenado; un ejemplo positivo (negativo) que el clasificador clasifica correctamente se denomina TP (verdadero negativo), un ejemplo positivo (negativo) que se clasifica incorrectamente se llama falso negativo (falso positivo). Los números se pueden organizar y calcular en todas las medidas deseadas como (ROKACH & MAIMON, 2015):

Rokach & Maimon (2015) indican que el concepto de sobreajuste es muy importante en la minería de datos. Se refiere a la situación en la que el algoritmo de inducción genera un clasificador que se ajusta perfectamente a los datos de entrenamiento, pero ha perdido la capacidad de generalizar a instancias no presentadas durante el entrenamiento. En otras palabras, en lugar de aprender, el clasificador simplemente memoriza las instancias de entrenamiento: el sobreajuste generalmente ocurre cuando el árbol tiene demasiados nodos relativos a la cantidad de datos de entrenamiento disponibles. Al aumentar el número de nodos, el error de entrenamiento generalmente disminuye, mientras que en algún momento el error de generalización empeora.

2.12 VALIDACIÓN DE LOS MAPAS

Olofsson et al. (2013) dicen que la validación de los mapas se realiza mediante la estimación de la precisión y la incertidumbre de los mapas elaborados, puesto que el resultado con sensores remotos nunca es perfecto. Es por esto la necesidad de valorar un mapa mediante un diseño e implementación de una

evaluación de la precisión, determinando las verdaderas categorías mediante una imagen de referencia. Al comparar el mapa versus una referencia es posible obtener una matriz de error, pudiendo ser esta por omisión y comisión. Si el mapa presenta errores significativos es posible que los errores se generen desde la clasificación, por eso es imprescindible estimar los intervalos de confianza de las áreas del estudio y otros estimadores estadísticos.

2.12.1 Juicio de Expertos

El juicio de expertos es una técnica que muchas veces constituye el único indicador de la validez de contenido. Es una práctica generalizada que requiere interpretar y aplicar sus resultados de manera acertada, eficiente y con toda la rigurosidad metodológica y estadística, para permitir que la evaluación basada en la información obtenida de la prueba pueda ser utilizada con los propósitos para la cual fue diseñada.

El juicio de expertos se define como una opinión informada de personas con trayectoria en el tema, que son reconocidas por otros como expertos cualificados en éste, y que pueden dar información, evidencia, juicios y valoraciones. También plantean que los expertos pueden estar relacionados por educación similar, entrenamiento, experiencia, entre otros; y en este caso la ganancia de tener muchos expertos disminuye (ESCOBAR-PÉREZ & CUERVO-MARTINEZ, 2008).

Las etapas de procedimiento: Elaborar una descripción de las áreas, preparar las instrucciones para los jueces/expertos, realizar una plantilla para recogerlas respuestas de los jueces, seleccionar a los expertos que se han de consultar, recoger los juicios de los expertos, calcular la consistencia interjueces, aglutinar las estimaciones, calcular los límites de confianza (ISABEL DE ARQUER, 1994).

Skjong y Wentworht (2001) proponen los siguientes criterios de selección: (a) Experiencia en la realización de juicios y toma de decisiones basada en evidencia o experticia (grados, investigaciones, publicaciones, posición, experiencia y premios entre otras), (b) reputación en la comunidad, (c) disponibilidad y motivación para participar, y (d) imparcialidad y cualidades

inherentes como confianza en sí mismo y adaptabilidad. También plantean que los expertos pueden estar relacionados por educación similar, entrenamiento, experiencia, entre otros; y en este caso la ganancia de tener muchos expertos disminuye.

2.12.2 Matriz de Confusión

Según Molinero (2001), la matriz de confusión es una herramienta que permite evaluar la precisión de una clasificación. Está compuesta por filas y columnas; las filas corresponden a las clases reinterpretadas a partir de las imágenes base, mientras que las columnas corresponden a las clases provenientes de la clasificación (mapa). En la diagonal de la matriz se expresa el número de puntos de verificación donde concuerdan ambas fuentes (reinterpretación y mapas); los puntos ubicados en las zonas marginales suponen errores de asignación, ya sea errores de omisión y errores de comisión. Los residuales en filas indican tipos de cubierta reinterpretadas que no se incluyeron en el mapa, mientras que los residuales en columnas representan las categorías del mapa que no se ajustan con la reinterpretación. A partir de la matriz de confusión se puede calcular un indicador de precisión global del mapa, que considera la relación entre el número de puntos correctamente asignados (sumatoria de la diagonal) y el total de los lugares de referencia.

Algunos conceptos usados en el resultado de la matriz de confusión según Zamora et al. (2016) son: Error de comisión: error que resulta de la clasificación, en la cual un pixel correspondiendo a una clase de cobertura no es clasificada de esa manera; error de omisión: error que resulta de la clasificación, en la cual un pixel es clasificado como una clase de cobertura a la que no pertenece; exactitud: nivel de concordancia entre el valor real y el resultado de las observaciones o estimaciones de una característica y precisión: el nivel de concordancia entre medidas repetidas de la misma característica. Se representa como una estrecha agrupación de resultados de los puntos de muestreo o parcelas. La precisión es inversamente proporcional al error.

2.12.3 Índice Kappa

El índice de Kappa es un estimador que refleja la concordancia entre dos observaciones. Puede tomar valores entre 0 y 1; mientras más cercano a 1, mayor es el grado de concordancia entre las observaciones (CERDA LORCA; VILLARROEL DEL P., 2008). Según Sánchez (2009) el índice Kappa es una forma de medir la exactitud del mapa. Este coeficiente toma en cuenta los errores de comisión y de omisión (TABLA 10).

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Donde:

r: número de filas

xi: número de observaciones en una fila i y una columna i

xi y x+i: son los totales marginales de una fila i y una columna i respectivamente.

N: total de número de observaciones.

TABLA 10 - VALORACIÓN DEL ÍNDICE KAPPA

Índice Kappa	Fuerza de Concordancia
0.00	Pobre
0.01 – 0.20	Leve
0.21 – 0.40	Aceptable
0.41 – 0.60	Moderada
0.61 – 0.80	Considerable
0.81 – 1.00	Casi perfecta

FUENTE: Cerda y Villarroel (2008).

La validación de un mapa de uso y cobertura de la tierra se refiere a un conjunto de técnicas necesarias para determinar su calidad, que se divide en tres puntos principales: el diseño de la muestra, la estrategia de verificación y el protocolo de análisis y estimación del resultado (STEHMAN; CZAPLEWSKI, 1998). Incluye la evaluación de la precisión mediante la comparación de los resultados de la imagen clasificada y otras fuentes de información, en observaciones basadas en un diseño de muestra probabilístico, lo que permite la estimación de la precisión global, la precisión del productor y del usuario y los errores de omisión y comisión (STRAHLER et al., 2006).

3 MATERIALES Y MÉTODOS

3.1 DESCRIPCIÓN DEL ÁREA DE ESTUDIO

El departamento de Ucayali, fue creado mediante Decreto (Ley 23099, 1980), sobre las bases de las provincias de Ucayali y Coronel Portillo, y por el decreto Ley N° 23416 el 01 en 1982. En la actualidad tiene cuatro provincias: Coronel Portillo, Atalaya, Padre Abad y Purús, con su capital es la ciudad de Pucallpa.

El departamento de Ucayali se encuentra ubicado en la parte central y oriental del territorio peruano, región de la selva Amazónica y forma parte de la selva baja (Gobierno Regional de Ucayali, 2015). La altitud del territorio del departamento de Ucayali es entre los 111 m.s.n.m. (el centro poblado Santa Clotilde - distrito de Callería - provincia de Coronel Portillo) y los 2 348 m.s.n.m. (en las nacientes del río Santa Ana, del distrito Padre Abad - provincia Padre Abad, en límite con el distrito José Crespo y Castillo, provincia Leoncio Prado del departamento de Huánuco) (TABLA 11) (INEI, 2018).

TABLA 11 - PUNTOS EXTREMOS DEL DEPARTAMENTO DE UCAYALI

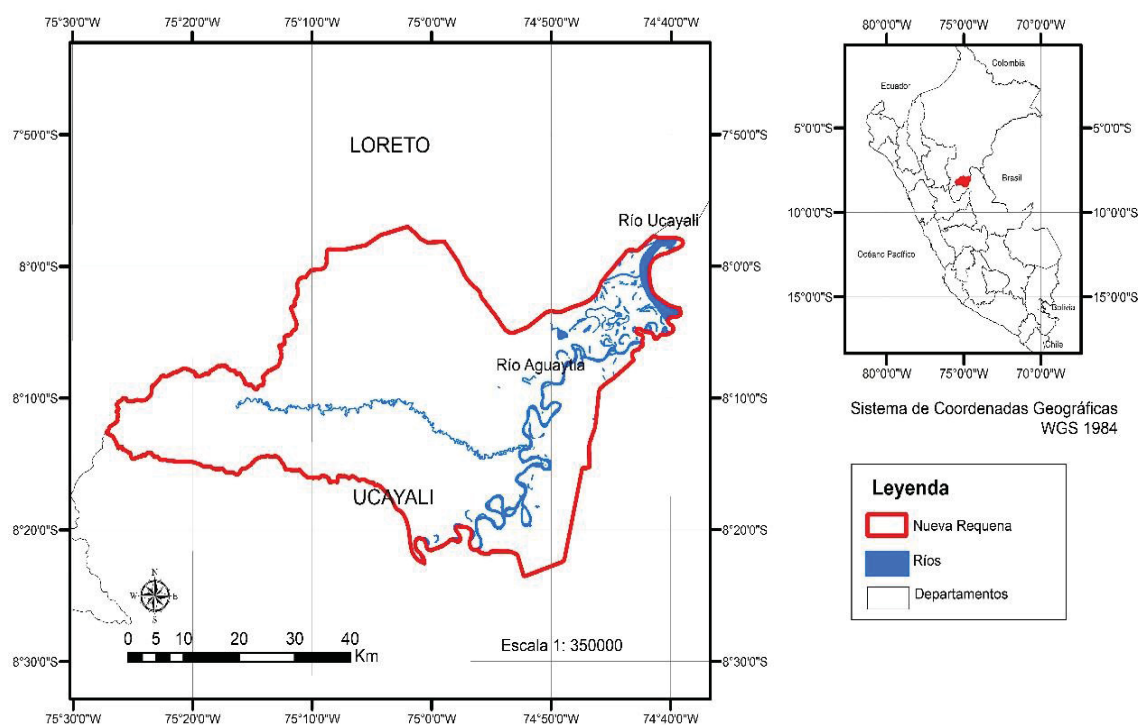
ORIENTACIÓN	Latitud Sur	Longitud oeste	Lugar
NORTE	07°20'23"	74°32'05"	Divisoria de aguas de los ríos Cashiboya, Alto Maquina, Callería y Trapiche
ESTE	09°25'09"	70°29'465"	Hito Santa Rosa, en la desembocadura del río Santa Rosa y sobre el río Alto Purús, límite con Brasil.
SUR	11°27'35"	72°34'55"	Punto sobre el río Alto Mishagua, aprox. 3,6 km al S.E. de la desembocadura del río Serjali, límite entre los departamentos de Ucayali y Cusco.
OESTE	08°40'19"	75°58'08"	Cumbre de las nacientes de los ríos Pisqui y Santa Ana, límite departamental con Loreto y Huánuco.

FUENTE: INEI, 2018.

El departamento de Ucayali representa el 7,97% del territorio nacional con una extensión de 101 830,64 km². La región Ucayali tiene clima de selva tropical, permanentemente húmedo y cálido. El eje central de la principal red hidrográfica es el río Ucayali, el cual tiene numerosos afluentes, siendo los más importantes los ríos Urubamba y Tambo al sur, y los ríos Pachitea y Aguaytía al norte y una población de 496 459 habitantes según el Censo Nacional 2017(INEI, 2018).

El área de estudio de la investigación es el distrito de Nueva Requena que se ubica en la provincia de Coronel Portillo del departamento de Ucayali, creado con disposición de ley N°26352 (Gobierno Regional de Ucayali, 2015) del 14 de setiembre de 1994. Tiene como ubicación las coordenadas $8^{\circ}20'03''\text{S}$ $74^{\circ}33'43''\text{O}$ y una extensión de $1857,82 \text{ km}^2$ (FIGURA 14) (TABLA 12). Nueva Requena tiene una altitud media de 153 m.s.n.m, con una población total de 5 169 habitantes siendo el mayor grupo poblacional el grupo de edades de 1 a 14 años (INEI, 2018). El río Aguaytía cruza el distrito. El clima tropical, con precipitaciones durante todo el año, tiene una precipitación promedio es de 1 974 mm distribuidas en dos épocas de abril a julio y de agosto a febrero. Tiene una temperatura media anual de $26,5^{\circ}\text{C}$ y la humedad varía 75 a 85 % (Gobierno Regional de Ucayali, 2015).

FIGURA 14 - UBICACIÓN DEL DISTRITO DE NUEVA REQUENA



FUENTE: La autora (2019).

TABLA 12 - FRONTERAS DEL DISTRITO DE NUEVA REQUENA

Dirección	Fronteras
	Nueva Requena
Norte	departamento de Loreto
Este	distrito de Callería y Yarinacocha
Sur	distrito de Campo Verde
Oeste	departamento de Huánuco

FUENTE: Gobierno Regional de Ucayali (2015).

3.2 EQUIPOS Y MATERIALES

Los equipos, programas e insumos digitales usados en todos los procesos realizados en esta investigación fueron: (TABLA 13), (ANEXO 1).

TABLA 13 – EQUIPOS, PROGRAMAS E INSUMOS

	Equipos	Programas	Insumos Digitales
Pre-Procesamiento	<ul style="list-style-type: none"> Computadora HP Z240 serie Tower Workstation 	<ul style="list-style-type: none"> ERDAS IMAGINE 2014 PCI Geomática 2018 ArcMap10.5 Microsoft Office 2010 Notepad ++ 	<ul style="list-style-type: none"> (8) Sentinel- 2B (bandas 2;3 y 4) (4) Sentinel-1A (banda C) Mosaico Libre de nubes de Landsat 2011 (GEOBOSQUES, 2019) Capa Política del Perú (INEI,2015) Capa provincial de Ucayali (INEI,2015) Capa distrital de la provincia de Coronel Portillo (INEI,2015)
Procesamiento	<ul style="list-style-type: none"> ASUS ROG G752VT-DH72 de 17 pulgadas. Core I7 	<ul style="list-style-type: none"> ERDAS IMAGINE 9.2 (NLCD) 	<ul style="list-style-type: none"> (8) Sentinel- 2B (bandas 2;3 y 4) (4) Sentinel-1A (banda C)
Modelo 1		<ul style="list-style-type: none"> ERDAS IMAGINE 2014 	<ul style="list-style-type: none"> Leyenda IPCC (GEOBOSQUES, 2019)
Modelo 2		<ul style="list-style-type: none"> PCI Geomática 2018 	
Modelo 3		<ul style="list-style-type: none"> ArcMap10.5 	
Modelo 4		<ul style="list-style-type: none"> See5 / C5 	
Post-Procesamiento		<ul style="list-style-type: none"> Microsoft Office 2010 Notepad ++ ArcMap10.5 	

Validación	<ul style="list-style-type: none"> • Computadora HP Z240 serie Tower Workstation • ASUS ROG G752VT-DH72 de 17 pulgadas. Core I7 • Cámara fotográfica GOPRO Hero 5 • GPSMap 62 S Garmin 	<ul style="list-style-type: none"> • ArcMap10.5 • Pix4D mapper • Microsoft Office 2010 • Notepad ++ 	<ul style="list-style-type: none"> • Google Earth 2016 • (11) PERUSAT -1 • 1 PLANET • (13) Fotografías aéreas • Capa Política del Perú (INEI,2015) • Capa provincial de Ucayali (INEI,2015) • Capa distrital de la provincia de Coronel Portillo (INEI,2015)
------------	--	---	---

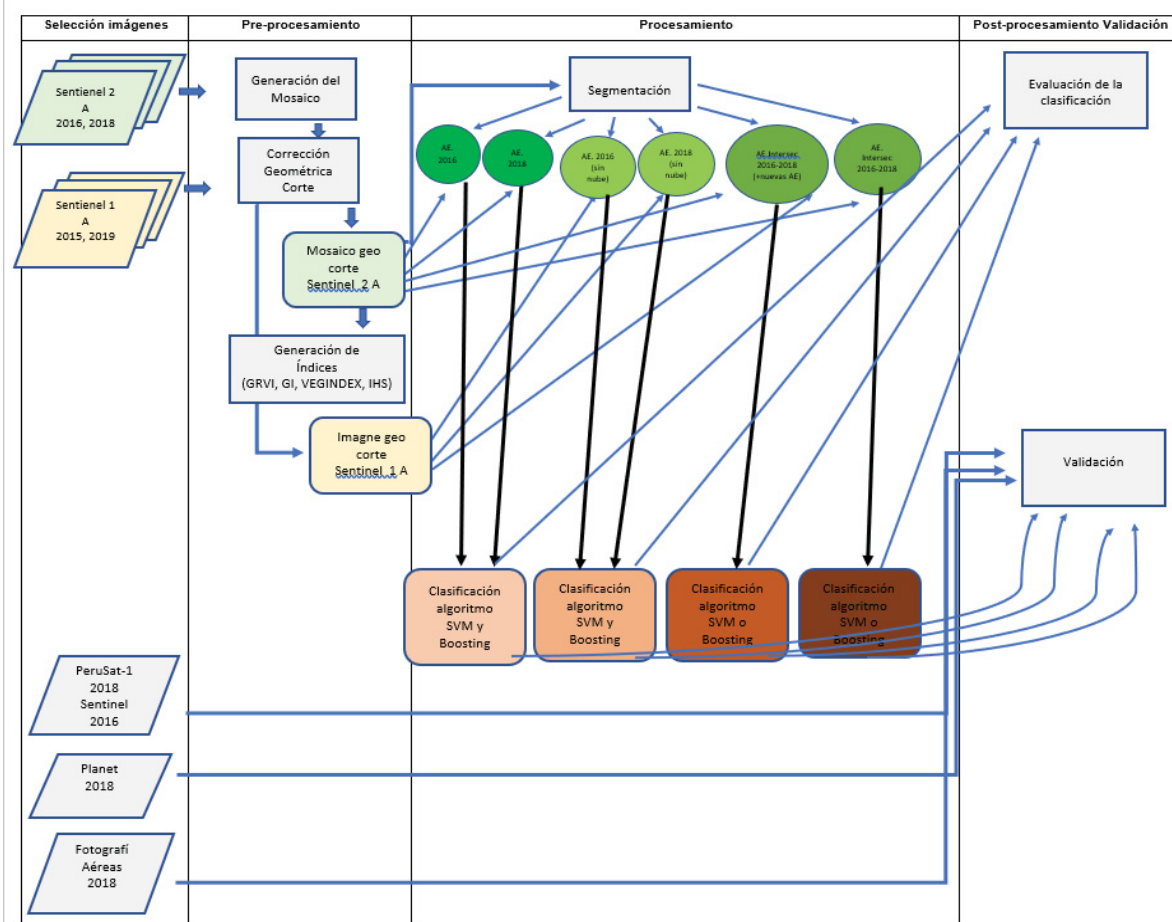
FUENTE: La autora (2019).

Continuación TABLA 13

3.3 METODOLOGÍA

El flujo metodológico realizado en la tesis se muestra en la FIGURA 15, donde se observa la selección de imágenes, pre-procesamiento, procesamiento, post-procesamiento y validación.

FIGURA 15 – FLUJO DEL PROCESO METODOLÓGICO



FUENTE: La autora (2019).

3.3.1 Selección de Imágenes

Todas las imágenes fueron descargadas del sitio web: Sentinel (2018)b.

3.3.2 Pre-Procesamiento

Para visualizar, procesar y analizar las imágenes satelitales pasivas fue necesario realizar la unión de bandas espaciales de las escenas que cubren la zona de estudio de los años 2016 y 2018. Se unieron (apilaron las capas o *Layer stack*) tres bandas de cada escena como se muestra en la TABLA 14; las longitudes de onda de las bandas utilizadas se encuentran en el espectro del visible porque es con estas longitudes de onda con las que se validarán los modelos realizados siendo las imágenes y fotografías aéreas en RBG de los años 2016 y 2018 (TABLA 14). Las imágenes del sensor activo de Sentinel-1A se usó la banda C (TABLA 15).

El proceso de unión de las bandas tiene como extensión resultante *.pix (ANEXO 2).

TABLA 14 - CARACTERÍSTICAS ESPECTRALES DE LAS BANDAS DEL SENSOR Sentinel- 2^a

Sensor Sentinel-2	Intervalos de longitudes de onda (µm)	Tamaño de píxel (m)
Banda 2	490 nm	10
Banda 3	560 nm	10
Banda 4	665 nm	10

FUENTE: Sentinel (2018)b.

TABLA 15 - CARACTERÍSTICA ESPECTRAL DEL SENSOR Sentinel-1^a

Sensor	Banda (µm)	Polarización	Tamaño de píxel (m)
Sentinel-1A	C	Polarimétrico	5 -40

FUENTE: Sentinel (2018)b.

Por la cantidad de imágenes satelitales requeridas para cubrir la zona de estudio fue necesario generar mosaicos de imágenes satelitales pasivas para los años 2016 y 2018. Esto se realizó en el programa PCI Geomática 2018, mediante la herramienta *Mosaic Tool*. La extensión del archivo resultante fue *.pix. Las imágenes activas de los años 2015 y 2019 no necesitaron el uso del mosaico puesto que una imagen cubre todo el distrito (ANEXO 3).

Luego se realizó la corrección geométrica o georreferenciación para cada mosaico mediante la herramienta *Auto Sync Workstation* del programa ERDAS IMAGINE 9.2 con una imagen referenciada y la que se deseaba corregir del área de estudio con puntos de control. Las imágenes de RADAR fueron referenciadas con ArcGIS 10.5 asignándole la proyección y datum que le correspondía.

Por último, se realizó el corte de los mosaicos, de las imágenes pasivas de los años 2016 y 2018 y activas de los años 2015 y 2019, en función de los límites políticos del distrito de Nueva Requena. Este pre-proceso se realizó con el programa PCI Geomática 2018 y la herramienta *clipping/subsetting*.

Como parte de un insumo, a parte de las imágenes se utilizaron los siguientes índices: El GRVI o índice de proporción verde y el GI o índice de verdor, ambos índices usados en el espectro visible, generados con el programa PCI Geomática 2018 con la herramienta VEGINDEX. Se aplicó el proceso IHS (intensidad, tono y saturación), pero de este proceso solo se consideró la saturación; esto también se realizó en PCI Geomática 2018.

Antes de realizar las clasificaciones, se agruparon en cuatro modelos en función a los algoritmos usados, imágenes e insumos de las mismas. Los modelos se muestran a continuación:

- a) Modelo 1: La clasificación se realizó a cada mosaico de sensores pasivos por separado (año 2016 y año 2018 independientemente), para luego, mediante un álgebra de mapas, obtener el cambio de uso de la tierra para ese período.
- b) Modelo 2: La clasificación se realizó a cada imagen de sensor activo (año 2015 y año 2019 independientemente) para luego, mediante un álgebra de mapas, obtener el cambio de uso de la tierra para ese período.

- c) Modelo 3: La clasificación se realizó sobre la fusión de los mosaicos de sensores pasivos (año 2016 y año 2018); el resultado del cambio de uso de la tierra se realizó de forma directa (sin realizar el álgebra de mapa).
- d) Modelo 4: La clasificación se realizó sobre la fusión de los mosaicos de sensores pasivos y activos (año 2016, año 2018, año 2015 y año 2019), siendo el resultado directamente el cambio de uso de la tierra.

3.3.3 Procesamiento

Basado en la leyenda del Grupo intergubernamental de expertos sobre el cambio climático (IPCC), leyenda usada oficialmente en el Perú, (TABLA 16), se decidió usar la misma clave de identificación para el cambio de uso de la tierra, teniendo en cuenta que el análisis es de dos períodos diferentes.

TABLA 16 -CLAVE DE IDENTIFICACIÓN DE USO DE LA TIERRA

Código	Descripción IPCC	Descripción Sub Clase
01	Tierras Forestales	Bosque
		Coberturas inundables en bosque
02	Tierras Agrícolas	Agricultura
03	Praderas	Vegetación secundaria
		Pastizales /Herbazales
		Sabanas Hidromórficas
04	Humedales	Cuerpos de Agua
		Coberturas inundables en No bosque
05	Asentamientos	Áreas Artificiales
		Áreas mineras
06	Otras tierras	Suelo desnudo

FUENTE: GEOBOSQUES (2019).

Otro proceso realizado fue la segmentación de las imágenes satelitales pasivas, considerando los parámetros: escala, forma y compacidad. Este paso fue necesario realizarlo solo en las imágenes pasivas y para trabajar el algoritmo *Support Vector Machine* en el programa PCI Geomática 2018 en su herramienta de segmentación dentro del clasificador supervisado análisis de objetos (ANEXO 4).

Los segmentos por sí solos, no pueden ser usados para la clasificación supervisada, así que se asignó un atributo en función de la clave de identificación planteada. A partir de la interpretación visual de las características de las imágenes

como forma, tono, color, textura, tamaño y con la experiencia del especialista se realizó la asignación manualmente, convirtiéndose algunos de los segmentos en áreas de entrenamiento. Este proceso se realizó en el programa PCI Geomática 2018 y la herramienta Análisis de Objetos. Las áreas de entrenamiento no fueron las mismas en todos los procesos ya que la naturaleza de las imágenes y los procesos deseados eran diferentes (TABLA 17) (ANEXO 5). Las áreas de entrenamiento creadas en el programa PCI fueron exportadas como ráster en el programa ERDAS IMAGINE 9.2 para clasificar con el algoritmo *Boosting* o árboles de decisión (ANEXO 6). Las áreas de entrenamientos fueron creadas en base a las imágenes satelitales pasivas y aplicadas en las activas dependiendo el modelo que se realizó.

TABLA 17 - GENERACIÓN DE LAS ÁREAS DE ENTRENAMIENTO (AE)

Algoritmo	Algoritmo <i>Support Vector Machine</i> (SVM): Análisis de Objetos			
	Algoritmo <i>Boosting</i>: Árboles de decisión			
Modelo	Modelo 1	Modelo 2	Modelo 3	Modelo 4
	Cambio de uso de la tierra 2016-2018	Cambio de uso de la tierra 2015-2019	Cambio de uso de la tierra 2016-2018	Cambio de uso de la tierra 2015 - 2016-2018- 2019
Área de Entrenamiento	AE- 2016	AE- 2016	Intersección de	Intersección de
	AE- 2018	AE- 2018	AE- 2016	AE- 2016
		(sin clase nubes ni sombra de nubes)	AE- 2018	AE- 2018
			(y nuevas AE)	
	AE- 2016	AE- 2016	Intersección de	Intersección de
	AE- 2018	AE- 2018	AE- 2016	AE- 2016
		(sin clase nubes ni sombra de nubes)	AE- 2018	AE- 2018
			(y nuevas AE)	

FUENTE: La autora (2019).

Se realizó una clasificación supervisada con dos algoritmos diferentes, así como con insumos de sensores remotos diferentes (TABLA 18 y TABLA 19).

TABLA 18 - CLASIFICACIÓN MEDIANTE EL ALGORITMO *SUPPORT VECTOR MACHINE* (SVM)

Análisis de Objetos: Algoritmo <i>Support Vector Machine</i> (SVM)						
Programa PCI Geomática 2018						
Modelo	Clasificación 1 Cambio de uso de la tierra 2016-2018		Clasificación 2 Cambio de uso de la tierra 2015-2019		Clasificación 3 Cambio de uso de la tierra 2016-2018	Clasificación 4 Cambio de uso de la tierra 2015-2016-2018- 2019
	Imágenes independientes		Imágenes independientes		Imágenes fusionadas	Imágenes fusionadas
Insumo	Sentinel 2A 2016	Sentinel 2A 2018	Sentinel 1A 2015	Sentinel 1A 2019	Sentinel 2A 2016 Sentinel 2A 2018	Sentinel 2A 2016 Sentinel 2A 2018 Sentinel 1A 2015 Sentinel 1A 2019

FUENTE: La autora (2019).

La clasificación con el algoritmo *Support Vector Machine* (SVM) se realizó con el programa PCI Geomática 2018; solo con este algoritmo se trabajó con las medianas de las bandas espectrales de las imágenes pasivas, los índices y / o las diferentes polarizaciones de las imágenes activas. El SVM se aplicó en el modelo análisis de objetos y con la función SVM *Kemel* y *Radial-basis* y el dato normalizado (ANEXO 7).

TABLA 19 -CLASIFICACIÓN MEDIANTE EL ALGORITMO *BOOSTING*

Arboles de decisión: Algoritmo <i>Boosting</i>						
Programa de ERDAS IMAGINE 9.2						
Modelo	Clasificación 1 Cambio de uso de la tierra 2016- 2018		Clasificación 2 Cambio de uso de la tierra 2015- 2019		Clasificación 3 Cambio de uso de la tierra 2016- 2018	Clasificación 4 Cambio de uso de la tierra 2015 - 2016-2018- 2019
Insumo	Imágenes independientes		Imágenes independientes		Imágenes fusionadas	Imágenes fusionadas
	Sentinel 2A 2016	Sentinel 2A 2018	Sentinel 1A 2015	Sentinel 1A 2019	Sentinel 2A 2016 Sentinel 2A 2018	Sentinel 2A 2016 Sentinel 2A 2018 Sentinel 1A 2015 Sentinel 1A 2019

FUENTE: La autora (2019).

La clasificación supervisada con el algoritmo *Boosting* empieza con las áreas de entrenamientos, insumo importante usado en el módulo NLCD del programa ERDAS IMAGINE 9.2. Se preparó la imagen a clasificar discriminando una variable independiente (imagen de estudio) y una variable dependiente (ráster de las áreas de entrenamiento); este proceso arroja tres archivos diferentes *.names, *.data, *.test.

Todos estos archivos fueron necesarios para el uso del programa estadístico See5 / C5 que es el responsable de generar el árbol de decisión *. Tree. Al finalizar el proceso se realizó la clasificación mediante el módulo NLCD del programa ERDAS IMAGINE 9.2 donde se obtuvo como resultado la clasificación deseada (ANEXO 8, ANEXO 9, ANEXO 10, ANEXO 11, ANEXO 12).

3.3.3.1 Modelo 1: Clasificación supervisada del cambio de uso de la tierra 2016 - 2018

La metodología usada para el modelo 1, empleó como insumos las imágenes satelitales pasivas del 2016 y 2018. Estas imágenes se clasificaron en forma independiente mediante dos algoritmos diferentes; el algoritmo *Support Vector Machine* (SVM) en el módulo de análisis de objetos del programa PCI Geomática 2018 y el algoritmo *Boosting* en el módulo NLCD ERDAS IMAGINE 9.2 y en el programa de See 5 C5. Las áreas de entrenamiento usadas para esta clasificación fueron generadas para cada año independientemente.

Los resultados parciales de la clasificación de cada año se transformaron a vectores en el programa Arc Map 10.5 para luego unir las clasificaciones del año 2016 y 2018 y tener como resultado el Cambio de uso de la tierra en el período 2016-2018.

3.3.3.2 Modelo 2: Clasificación supervisada del Cambio de uso de la tierra 2015 - 2019

El modelo 2 empleó como insumos imágenes satelitales activas. Estas imágenes se clasificaron en forma independiente mediante dos algoritmos diferentes; *Support Vector Machine* (SVM) en la plataforma de análisis de objetos del programa PCI Geomática 2018 y algoritmo *Boosting* en la plataforma NLCD ERDAS IMAGINE 9.2 y See 5 C5. Las áreas de entrenamiento usadas para esta clasificación fueron las mismas generadas por el modelo 1 para cada año.

De la misma manera que el modelo 1 las clasificaciones fueron parciales para cada año; luego se transformaron a vectores en el programa ArcMap 10.5. La clasificación del año 2015 se unió con las clasificaciones generadas para el año 2019 para tener como resultado el Cambio de uso de la tierra en el período 2015 - 2019.

3.3.3.3 Modelo 3: Clasificación supervisada del Cambio de uso de la tierra 2016 - 2018

El modelo 3 utilizó los insumos de imágenes satelitales pasivas unidas o agrupando las bandas entre ellas. Estas imágenes se clasificaron en forma conjunta (como si fuera una sola) mediante dos algoritmos diferentes: *Support Vector Machine* (SVM) en la plataforma de análisis de objetos del programa PCI Geomática 2018 y algoritmo *Boosting* en la plataforma NLCD ERDAS IMAGINE 9.2 y See 5 C5. Las áreas de entrenamiento usadas para esta clasificación fueron generadas de la intersección de las áreas de entrenamiento de cada año y se adicionó nuevas áreas de entrenamiento de cambio de uso de la tierra basado en las imágenes satelitales.

Los resultados de las clasificaciones fueron directos, no se produjeron resultados parciales para el cambio de uso de la tierra, para el período 2016 – 2018. Este resultado se transformó a vector en el programa ArcMap 10.5.

3.3.3.4 Modelo 4: Clasificación supervisada del Cambio de uso de la tierra 2015 - 2019

La metodología para el modelo 4 utilizó las imágenes satelitales pasivas e imágenes activas unidas entre bandas y combinación de polarizaciones, de la misma manera que los modelos anteriores usaron dos algoritmos diferentes *Support Vector Machine* (SVM) en la plataforma de análisis de objetos del programa PCI Geomática 2018 y algoritmo *Boosting* en la plataforma NLCD ERDAS IMAGINE 9.2 y See 5. Las áreas de entrenamiento usadas para esta clasificación fueron las mismas que se usaron para el modelo 3.

Este modelo generó como resultado el cambio de uso de la tierra para los años deseados en forma directa; luego fueron transformados a vectores en el programa Arc Map 10.5.

3.3.4 Post-Procesamiento

Basado en la clave de identificación de uso de la tierra (TABLA 20), fue necesario generar una clave de identificación del cambio de uso de la tierra que involucrase dos fechas para poder calcular el cambio. Esto se realizó con la combinación de las clases de la TABLA 16.

TABLA 20 - CLAVE DE IDENTIFICACIÓN DEL CAMBIO DE USO DE LA TIERRA

Código	Descripción cambio de uso de la tierra	Código	Descripción cambio de uso de la tierra
1010	Tierras Forestales – Tierras Forestales	4040	Humedales – Humedales
1020	Tierras Forestales – Tierras Agrícolas	4050	Humedales – Asentamientos
1030	Tierras Forestales – Praderas	4060	Humedales – Otras tierras
1040	Tierras Forestales – Humedales	4070	Humedales – No dato
1050	Tierras Forestales – Asentamientos	5010	Asentamientos – Tierras Forestales
1060	Tierras Forestales – Otras tierras	5020	Asentamientos – Tierras Agrícolas
1070	Tierras Forestales – No dato	5030	Asentamientos – Praderas
2010	Tierras Agrícolas – Tierras Forestales	5040	Asentamientos – Humedales
2020	Tierras Agrícolas – Tierras Agrícolas	5050	Asentamientos – Asentamientos
2030	Tierras Agrícolas – Praderas	5060	Asentamientos – Otras tierras
2040	Tierras Agrícolas – Humedales	5070	Asentamientos – No dato
2050	Tierras Agrícolas – Asentamientos	6010	Otras tierras – Tierras Forestales
2060	Tierras Agrícolas – Otras tierras	6020	Otras tierras – Tierras Agrícolas
2070	Tierras Agrícolas – No dato	6030	Otras tierras – Praderas
3010	Praderas – Tierras Forestales	6040	Otras tierras – Humedales
3020	Praderas – Tierras Agrícolas	6050	Otras tierras – Asentamientos
3030	Praderas – Praderas	6060	Otras tierras – Otras tierras
3040	Praderas – Humedales	6070	Otras tierras – No dato
3050	Praderas – Asentamientos	7010	No dato – Tierras Forestales
3060	Praderas – Otras tierras	7020	No dato – Tierras Agrícolas
3070	Praderas – No dato	7030	No dato – Praderas
4010	Humedales – Tierras Forestales	7040	No dato – Humedales
4020	Humedales – Tierras Agrícolas	7050	No dato – Asentamientos
4030	Humedales – Praderas	7060	No dato – Otras tierras
		7070	No dato – No dato

FUENTE: La autora (2019).

Al obtener resultados parciales en los modelos 1 y 2, fue necesario recodificar los resultados; de igual manera se hizo para el modelo 3 y 4 para uniformizar atributos. Esto se realizó en la base de datos de cada cambio de uso de la tierra en el programa ArcMap 10.5.

Por la gran cantidad, los polígonos resultantes se agruparon por clases para poder seguir con los análisis; esto fue realizado con el programa ArcMap 10.5 con la herramienta “*dissolve*”.

3.3.5 Análisis Estadístico

El análisis estadístico busca cuantificar la tasa de error de clasificaciones para diferentes clases o categorías. Para cada modelo se seleccionó muestras diferentes. El análisis inició con el desarrollo de las muestras o áreas de entrenamiento generadas de las imágenes satelitales. Estas se trabajaron con cada algoritmo deseado, estos con parámetros e iteraciones diferentes. El resultado fue la clasificación o modelo donde se obtiene el indicador deseado: tasa de error de clasificación para poder determinar el mejor modelo para el cambio de uso de la tierra.

El resultado de estas clasificaciones o modelos, generados en los programas PCI Geomática 2018 y ERDAS IMAGINE 9.2, presentan en los atributos del resultado, columnas denominadas *Training* (subconjunto de los datos para entrenar el modelo) y *Test* (subconjunto de los datos para probar el modelo entrenado). A través de esta información se procedió a realizar la matriz de confusión en los diferentes casos, con la finalidad de obtener la tasa de error de clasificación de los modelos.

Además, se cuantificó si se dio o no el cambio de uso de la tierra de un año al otro. Para determinar el mejor modelo, se tomó los modelos con menores tasas de error de clasificación. Al observar este indicador en los cuatro modelos se decidió convenientemente tomar como máximo 30% de tasa error de clasificación y así aceptar y considerar al modelo como bueno.

El objetivo fue asegurar que los cuatro modelos pudieran participar en la elección del mejor modelo con la validación de los mismos.

Se analizó el mejor modelo entre los obtenidos con tasa de error de clasificación aquellos que en la validación resultaron con el mejor índice Kappa y un Porcentaje correctamente clasificado alto, para tener el mejor modelo de clasificación supervisada para el cambio de uso de la tierra.

3.3.6 Validación del mapa

Uno de los modelos más importantes es la validación del mapa o de la clasificación. Eso motivó la realización de un sobrevuelo en el área de estudio en 2018, generándose fotografías aéreas imágenes satelitales de PERUSAT-1 distribuida por el CNOIS de forma gratuita a instituciones nacionales, así como una imagen PLANET.

Para utilizar las fotografías aéreas se trabajó con los programas Pix4Dmapper las fotografías aéreas, se usó una cámara fotográfica GOPRO Hero 5 Black colocada en la parte inferior de un avión de la policía Nacional. Las fotografías al ser tomadas desde una avioneta pasaron por un proceso de ortorectificación para hacer diferentes mosaicos y poder utilizarlas como validación de las clasificaciones. Fueron agrupados en subproyectos y se seleccionó para geolocalizarlas con los metadatos del GPS de la cámara. Se realizó la georreferenciación mediante la inserción de puntos de control terrestre (GCP).

Otro insumo necesario para la validación fueron las imágenes satelitales de PERUSAT-1, siendo ocho escenas y una escena de la imagen PLANET que cubrieron parcialmente el distrito de Nueva Requena para la validación del año 2018, se utilizó el programa PCI Geomática 2018 y mediante la herramienta *Mosaic Tool* se elaboró el mosaico, a pesar que el mosaico no cubre completamente el área de estudios con las imágenes PERUSAT -1 y PLANET. La validación del año 2016 se realizó con Google Earth 2016.

Sobre las imágenes de referencia fue necesario generar una red de puntos en función de las imágenes de validación disponibles. Se creó una red de puntos para la validación de todos los modelos para los años 2016 y 2018, se realizó mediante cuadrículas distribuidas cada 500 metros del total de las imágenes de referencia con herramienta “crear red de pesca” del programa ArcMap 10.5 ubicado en ArcToolbox/Datos/Herramientas de administración/Muestreo/Crear directorio de

res de pesca, siendo el tamaño de la celda de la cuadrícula de 500 m entre los puntos de referencia de la muestra (ANEXO 13), siendo 5095 utilizados para validar.

A cada punto generado se le asignó el atributo según las imágenes de validación en una capa vectorial. Luego estos puntos se compararon con cada una de las clasificaciones de cambio de uso de la tierra para los cuatro modelos usando el programa ArcMAP 10.5. Para validar cada modelo se añadió una columna de clasificación con dos valores 0 y 1, siendo 0 si ambos atributos coincidían y 1 si eran diferentes.

Para concluir la validación fue calculado el índice Kappa. Esto se realizó con las tres columnas antes mencionadas y el algoritmo *Random Forest* del programa R, determinando el nivel de exactitud y precisión del análisis de las clasificaciones realizadas.

Otro de los resultados de esta validación es la matriz de confusión que muestra los errores de comisión y omisión según lo evaluado en cada clase de las clasificaciones de cambio de uso de la tierra. El mejor modelo fue seleccionado en función de la tasa de error de clasificación y del índice de Kappa.

Para finalizar el proceso se calculó las superficies resultantes del modelo asignado como mejor.

4 RESULTADOS Y DISCUSIONES

4.1.1 Imágenes seleccionadas

Las imágenes satelitales seleccionadas fueron de Sentinel. Las imágenes pasivas fueron Sentinel 2-A de los años 2016 y 2018 con una resolución espacial de 10 m, con cuatro escenas que cubren la zona de estudio para cada año. Las imágenes activas fueron de Sentinel-1A, pero para la zona de estudio solo se encontraron las de los años 2015 y 2019 el área se cubrió con una sola imagen de 10 metros de resolución espacial.

4.1.2 Pre-Procesamiento

Se unieron las bandas del espectro visible de las imágenes de Sentinel-2A, con resolución espacial de 10m puesto que la validación también fue realizada con imágenes visibles y se deseó conservar la alta resolución espacial en todo momento.

La zona de estudio fue cubierta por cuatro escenas, de Sentinel-2A, de cada año de evaluación. Por ello fue necesario realizar un mosaico para el 2016 y un mosaico para el 2018. En el caso de las imágenes activas de Sentinel-1A no se requirió hacer este modelo por ser una sola escena que cubre al distrito.

Cada mosaico de las imágenes pasivas se georreferenció con el programa ERDAS IMAGINE 2014 (transformando la extensión de los archivos de *.pix a *.img). El mosaico de referencia fue el mosaico libre de nubes de Landsat del año 2011 por ser un mosaico usado de forma oficial en el estado peruano y por no contar con información con mayor resolución espacial. Los errores RMS generados en la georreferenciación para cada mosaico son mostrados en la Tabla 21 y 22.

TABLA 21 - ERROR DE GENERACIÓN - MOSAICO Sentinel-2A (2016)

Número de Puntos	Error de puntos de control	
	(x)	(Y)
14	0,4123	0,6232
Error RMS 0,7472		

FUENTE: La autora (2019).

TABLA 22 - ERROR DE GENERACIÓN - MOSAICO Sentinel-2A (2018)

Número de Puntos	Error de puntos de control	
	(x)	(Y)
13	0,4184	0,8915
Error RMS 0,9848		

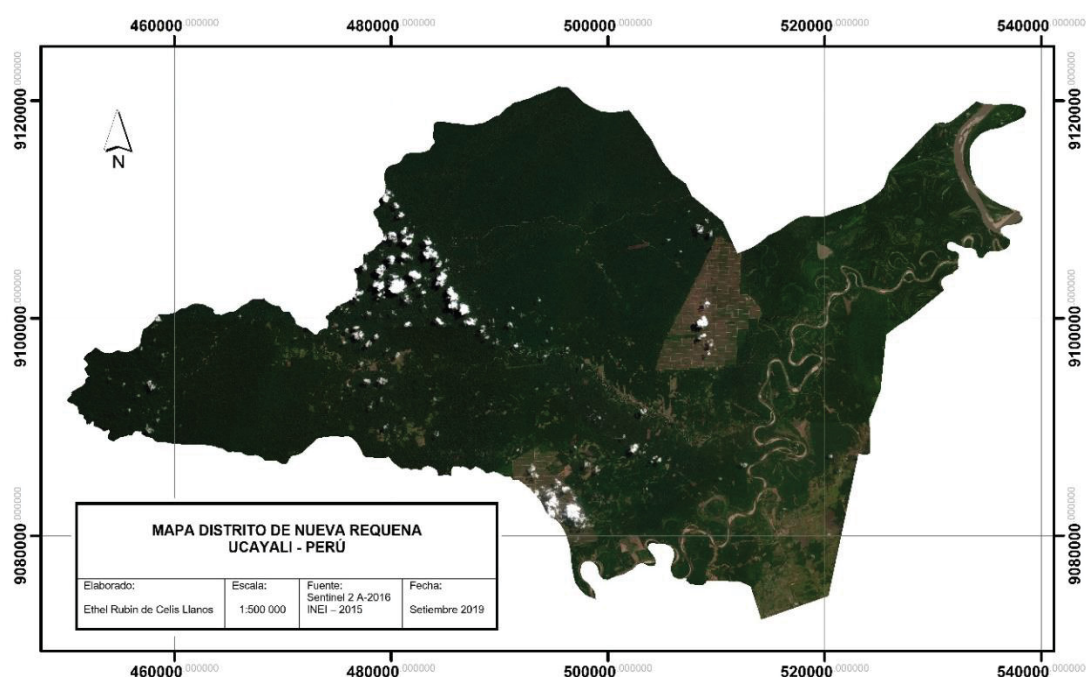
FUENTE: La autora (2019).

Esto significa que para el mosaico del 2016 el pixel de referencia está a aproximadamente a 20m del punto de transformación y para el mosaico del 2018 se encuentra aproximadamente a 30m. Este modelo sería ideal realizarlo con imágenes de alta resolución para que el error fuera mucho menor.

En el caso de las imágenes de RADAR se referenció con ArcGIS puesto que la asignación de puntos de control no se discrimina visualmente con una Proyección UTM, Datum WGS 84, Zona 18.

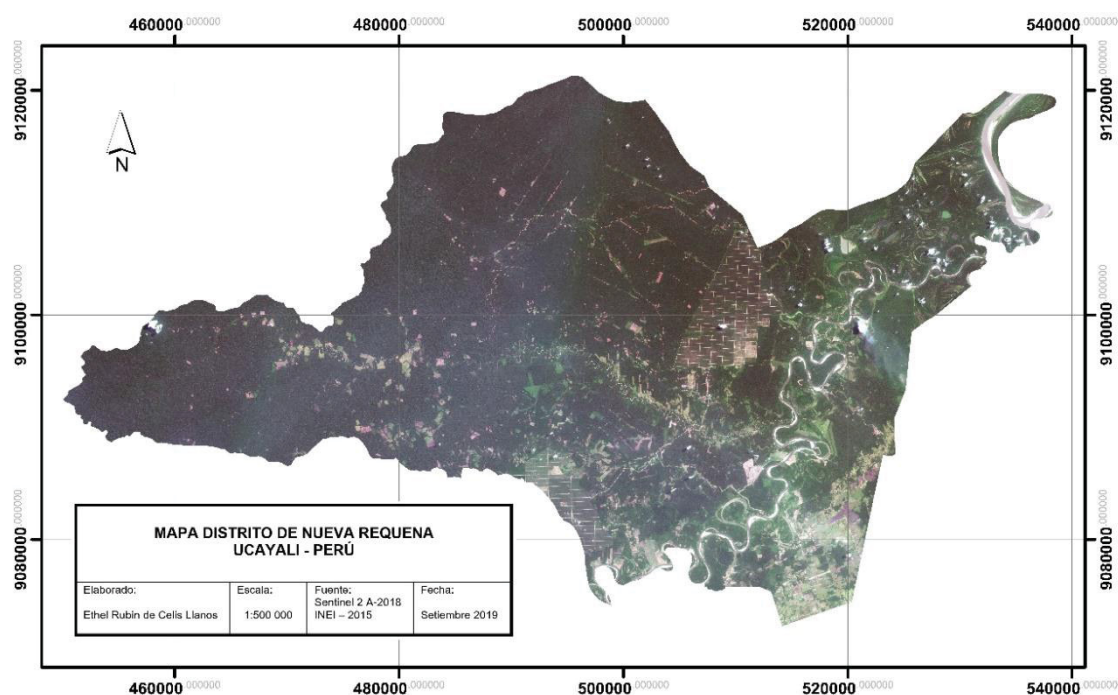
Por el importante volumen de espacio en los procesamientos y por la cantidad de clasificaciones a realizarse se cortaron los mosaicos de las imágenes pasivas y las imágenes de RADAR según la capa temática política del distrito de Nueva Requena (FIGURAS 16, 17, 18 y 19) (INEI, 2015).

FIGURA 16 - MAPA CORTE DEL MOSAICO Sentinel-2A AÑO 2016



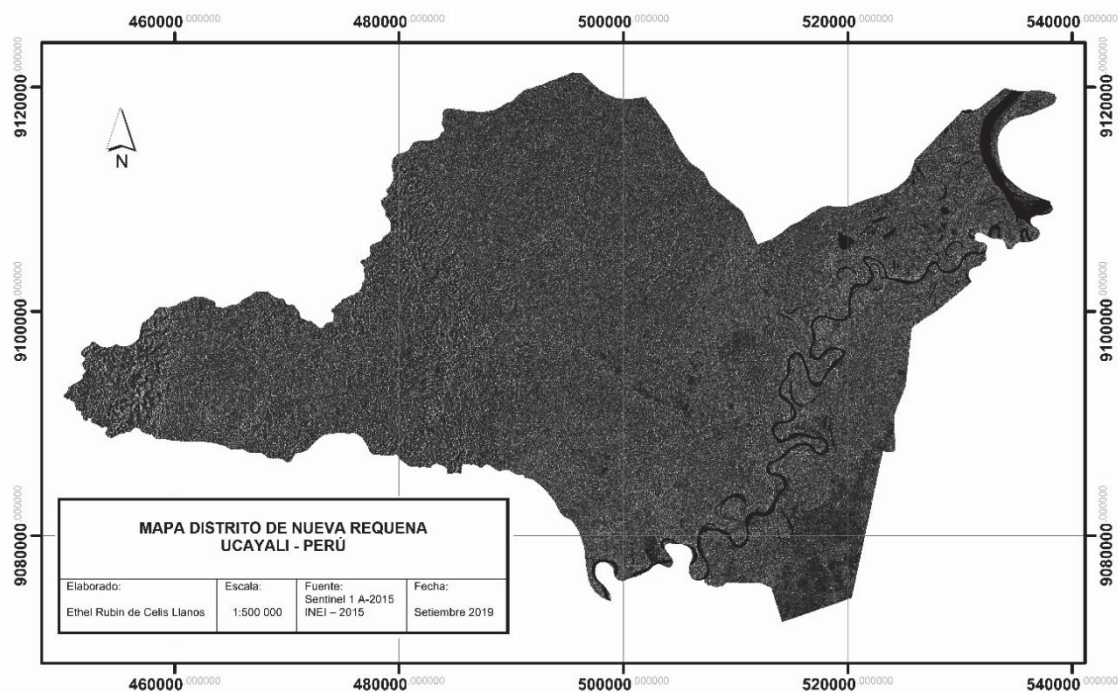
FUENTE: La autora (2019).

FIGURA 17 - MAPA CORTE DEL MOSAICO Sentinel-2A AÑO 2018



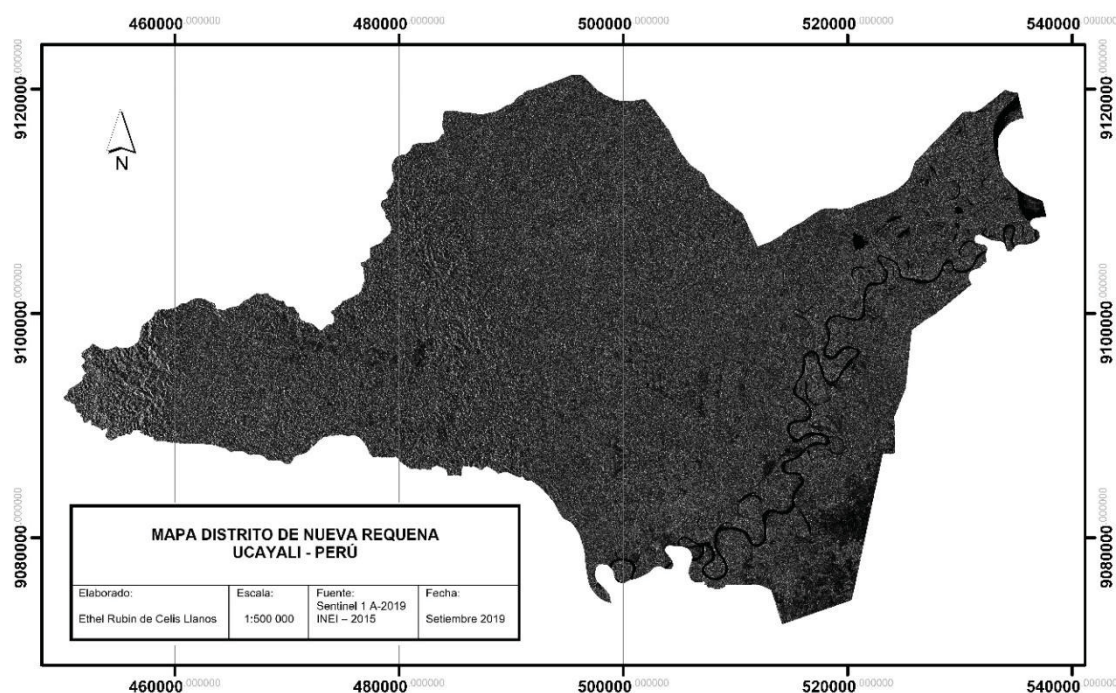
FUENTE: La autora (2019).

FIGURA 18 – MAPA CORTE Sentinel-1A AÑO 2015



FUENTE: La autora (2019).

FIGURA 19 - MAPA CORTE Sentinel-1A AÑO 2019



FUENTE: La autora (2019).

4.1.3 Procesamiento

El algoritmo *Support Vector Machine* (SVM) en la plataforma de PCI Geomática 2018 con el módulo análisis de objetos requiere que las imágenes a clasificar sean segmentadas. Los parámetros que generaron los mosaicos más adecuados fueron la escala a 25, la forma a 0,9 y la compacidad a 0,5 (FIGURA 20).

Para el mosaico 2016 fueron generados 71 104 segmentos y para el mosaico 2018, 46 715 segmentos.

FIGURA 20 - SEGMENTACIÓN DEL MOSAICO 2016

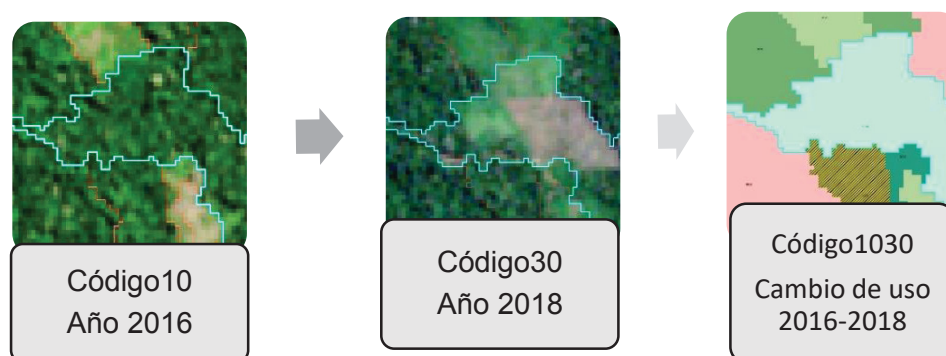


FUENTE: La autora (2019).

El proceso de segmentar las imágenes satelitales pasivas solo fue requerido para el algoritmo *Support Vector Machine*; este modelo no lo requiere el algoritmo *boosting* (árboles de decisión). Sin embargo, con el atributo asignado, algunos de los segmentos se convirtieron en áreas de entrenamiento para ambos algoritmos.

Los atributos asignados a las áreas de entrenamiento fueron códigos numéricos de cuatro dígitos, siendo los dos primeros dígitos del primer año analizado y los dos siguientes del segundo año (FIGURA 21) con base en la TABLA 20.

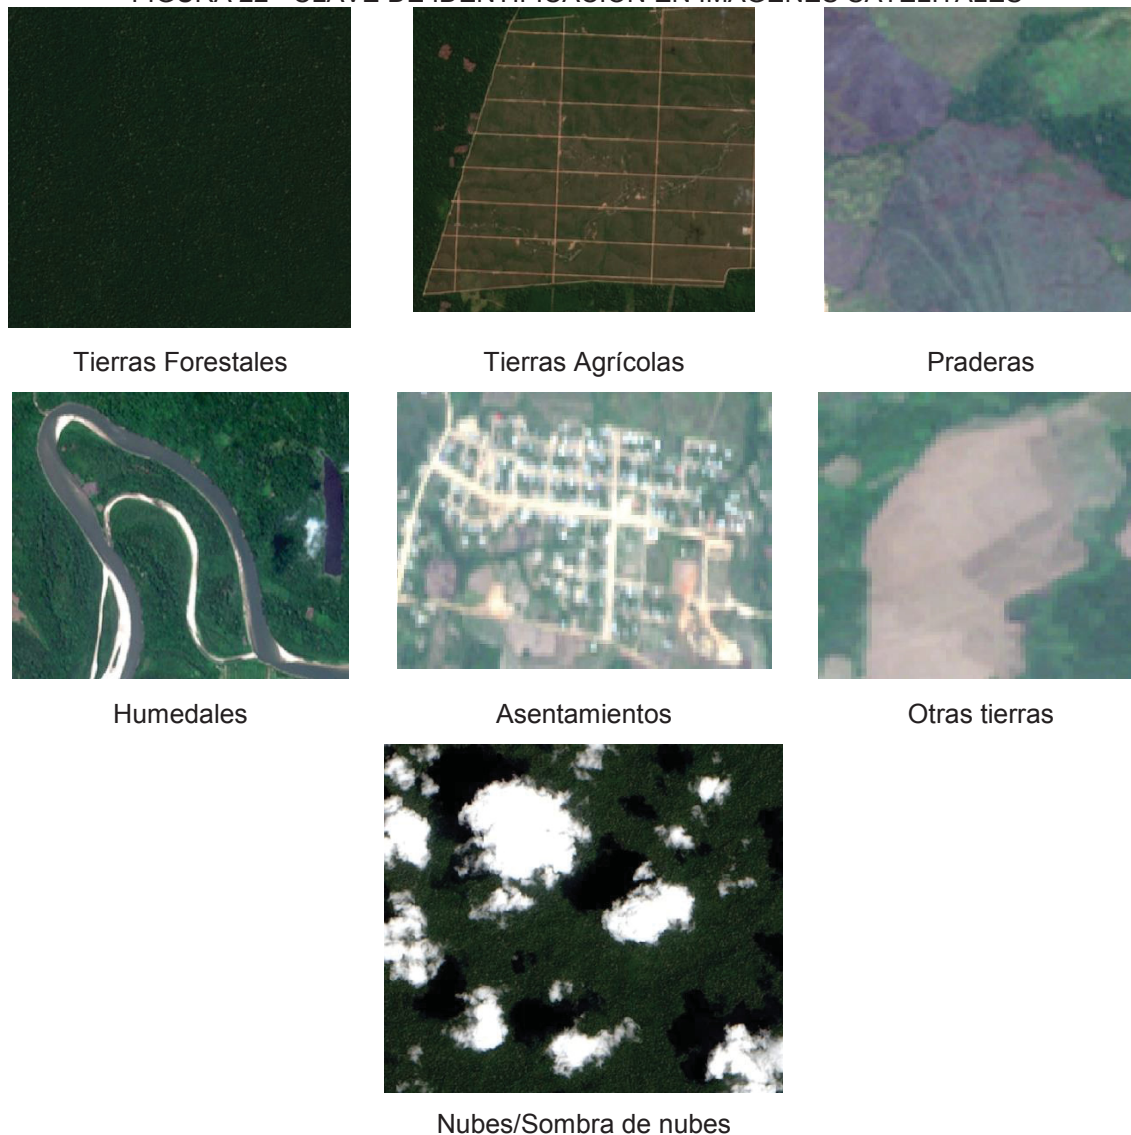
FIGURA 21 – EJEMPLO DE ASIGNACIÓN DE CÓDIGOS CLASIFICACIÓN



FUENTE: La autora (2019).

En base a la interpretación visual de las características de las imágenes como forma, tono, color, textura, tamaño y con la experiencia del especialista se realizó la asignación manualmente según la clave de identificación planteada (FIGURA 22). Estas áreas de entrenamiento variaron según los insumos usados (TABLA 23).

FIGURA 22 - CLAVE DE IDENTIFICACIÓN EN IMÁGENES SATELITALES



FUENTE: La autora (2019).

TABLA 23 - SEGMENTOS O ÁREA DE ENTRENAMIENTO POR MODELO

	Año 2016= 1359
Modelo 1	Año 2018= 953
	Cambio de uso del Modelo 1 = 2312
	Año 2015 = 1177
Modelo 2	Año 2019=708
	Cambio de uso del modelo 2 = 1885
Modelo 3	Cambio de uso del modelo 3 =278
Modelo 4	Cambio de uso del modelo 4 =272

FUENTE: La autora (2019).

Los insumos representados por imágenes derivadas de las bandas originales de los sensores pasivos solo fueron utilizados para las clasificaciones supervisadas con el algoritmo *Support Vector Machine* (TABLA 24). El algoritmo *Boosting* no utilizó ninguno de estos insumos.

TABLA 24 – VARIABLE O ATRIBUTOS DE LOS MOSAICOS PASIVOS

		Mediana Banda 2
Algoritmo		Mediana Banda 3
Support Vector	Sensor pasivo	Mediana Banda 4
Machine	Sentinel-2A	Saturación
SVM		Índice GRVI
		Índice GI

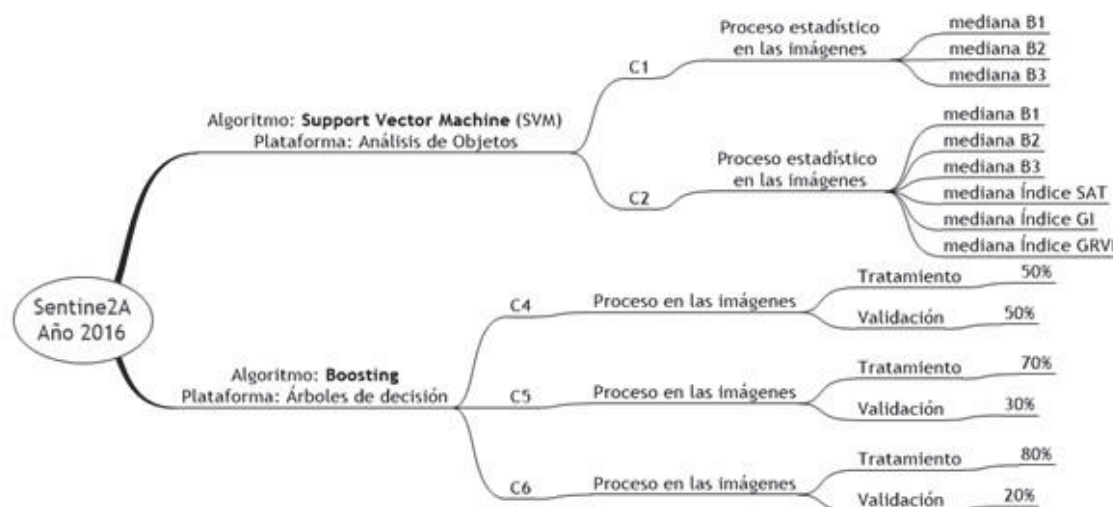
FUENTE: La autora (2019).

4.1.3.1 Clasificación

4.1.3.1.1 Modelo 1

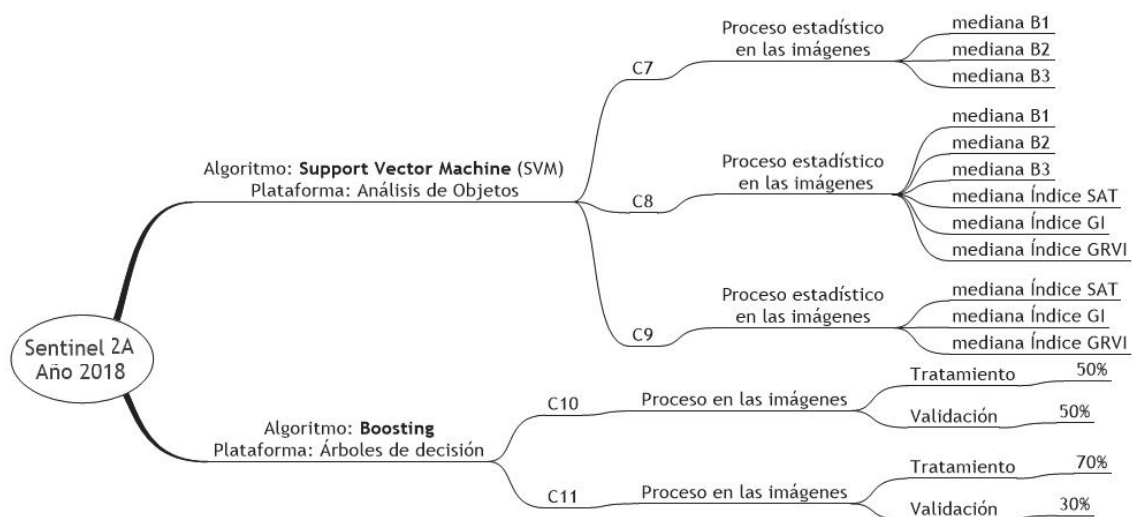
Cada clasificación se realizó en forma separada para cada año siendo el año 2016 y año 2018 con los diferentes atributos (FIGURA 23 y FIGURA 24). En la FIGURA 25 se muestran los resultados de las clasificaciones de todo el modelo 1.

FIGURA 23 - MODELO 1 - MOSAICO 2016




FUENTE: La autora (2019).

FIGURA 24 - MODELO 1 - MOSAICO 2018




FUENTE: La autora (2019).


FIGURA 25 - CAMBIO DE USO DE LA TIERRA MODELO 1




C1C7



C1C8




C1C9




C1C10




C2C11



C2C7




C2C8




C2C9




C2C10



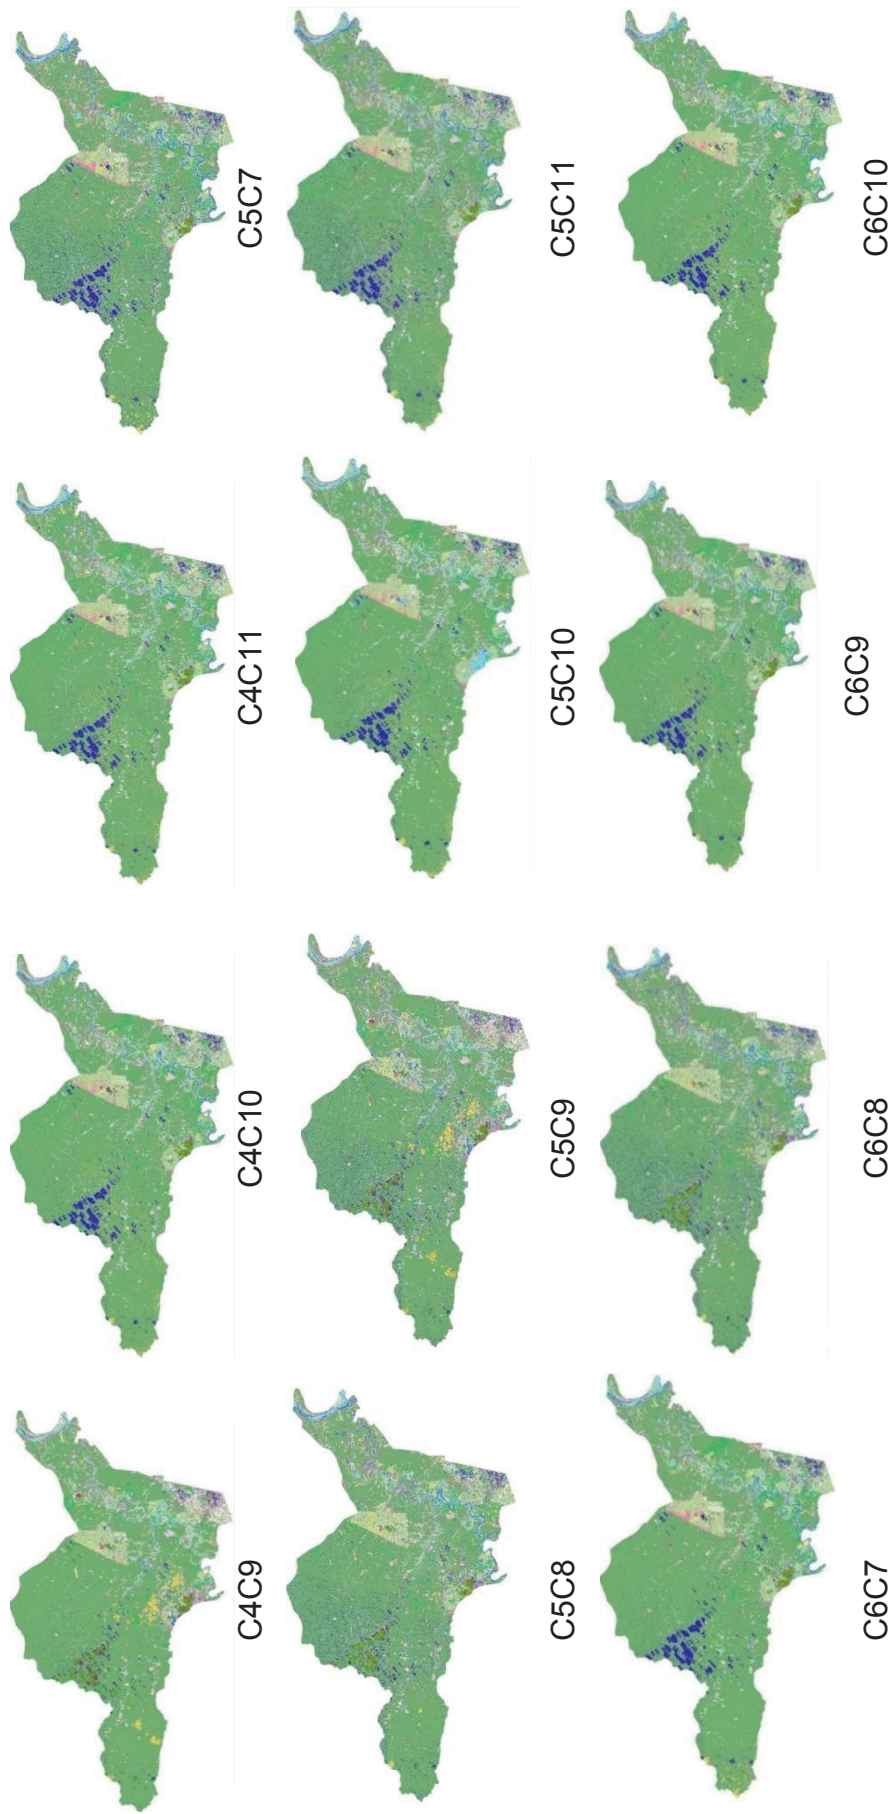
C2C11




C4C7



C4C8



Continuación FIGURA 25



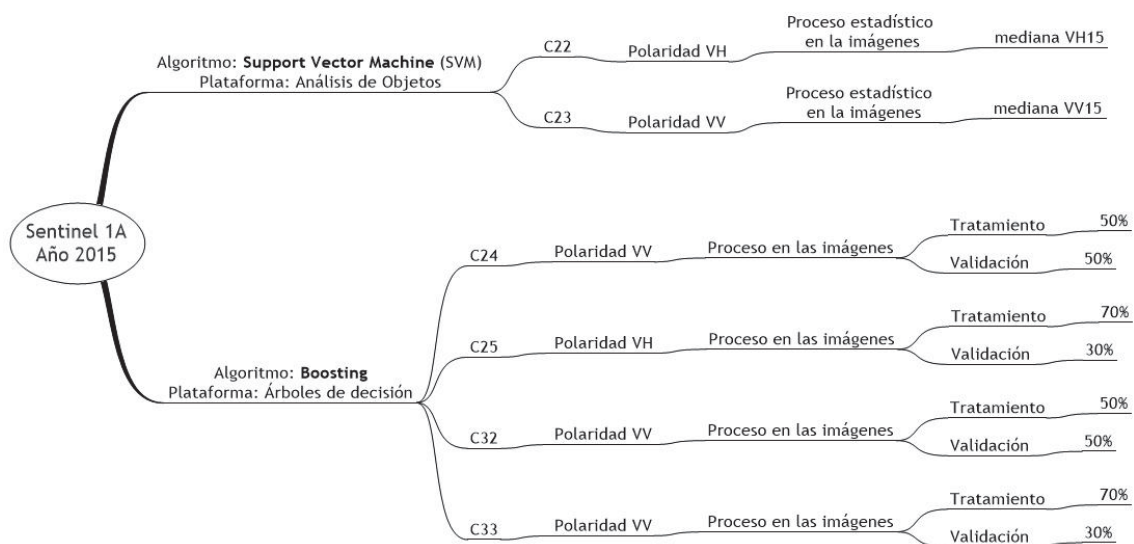
C6C11

Continuación FIGURA 25
FUENTE: La autora (2019).

4.1.3.1.2 Modelo 2

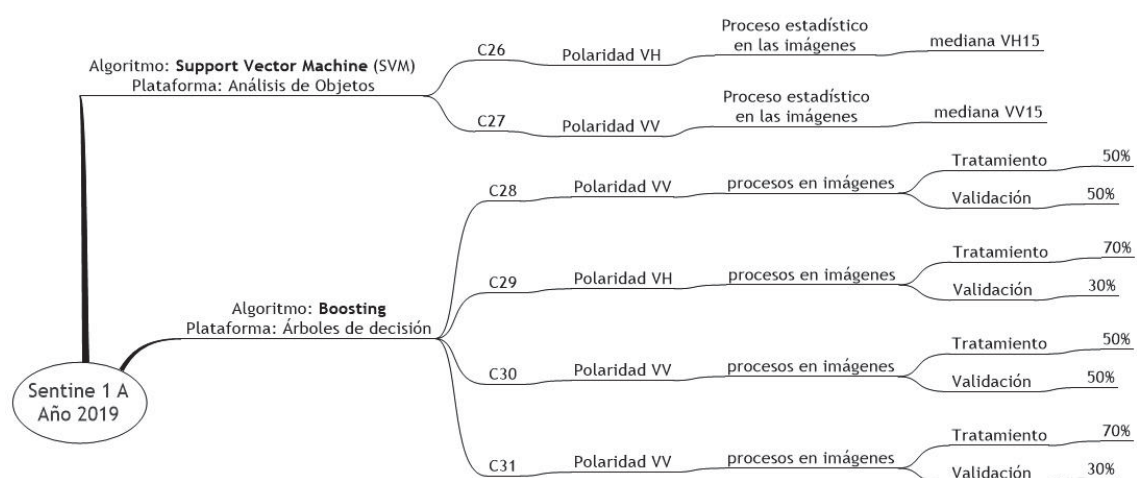
La clasificación se realizó a cada imagen de RADAR por separado siendo año 2015 y año 2019, para luego, mediante un álgebra de mapas obtenerse el cambio de uso de la tierra. Los insumos usados para los años 2015 y 2018 son mostrados en las Figuras 22 y 23 respectivamente (FIGURA 26 y FIGURA 27).

FIGURA 26 - MODELO 2 - IMAGEN DE RADAR 2015



FUENTE: La autora (2019).

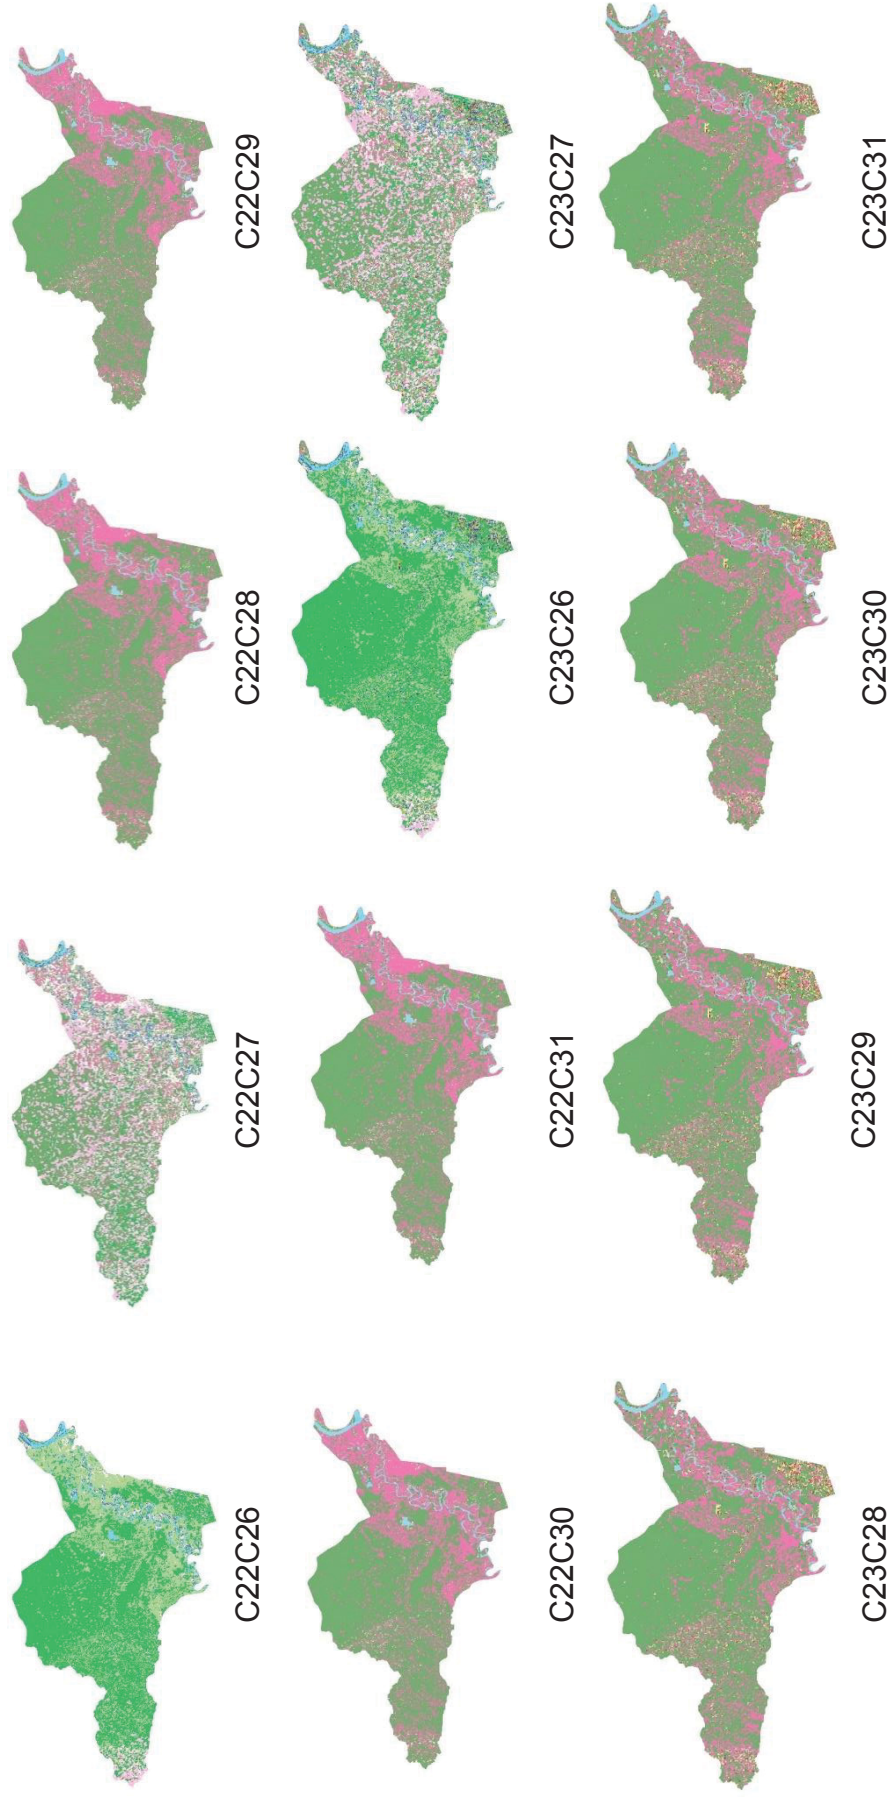
FIGURA 27 - MODELO 2 - IMAGEN DE RADAR 2019

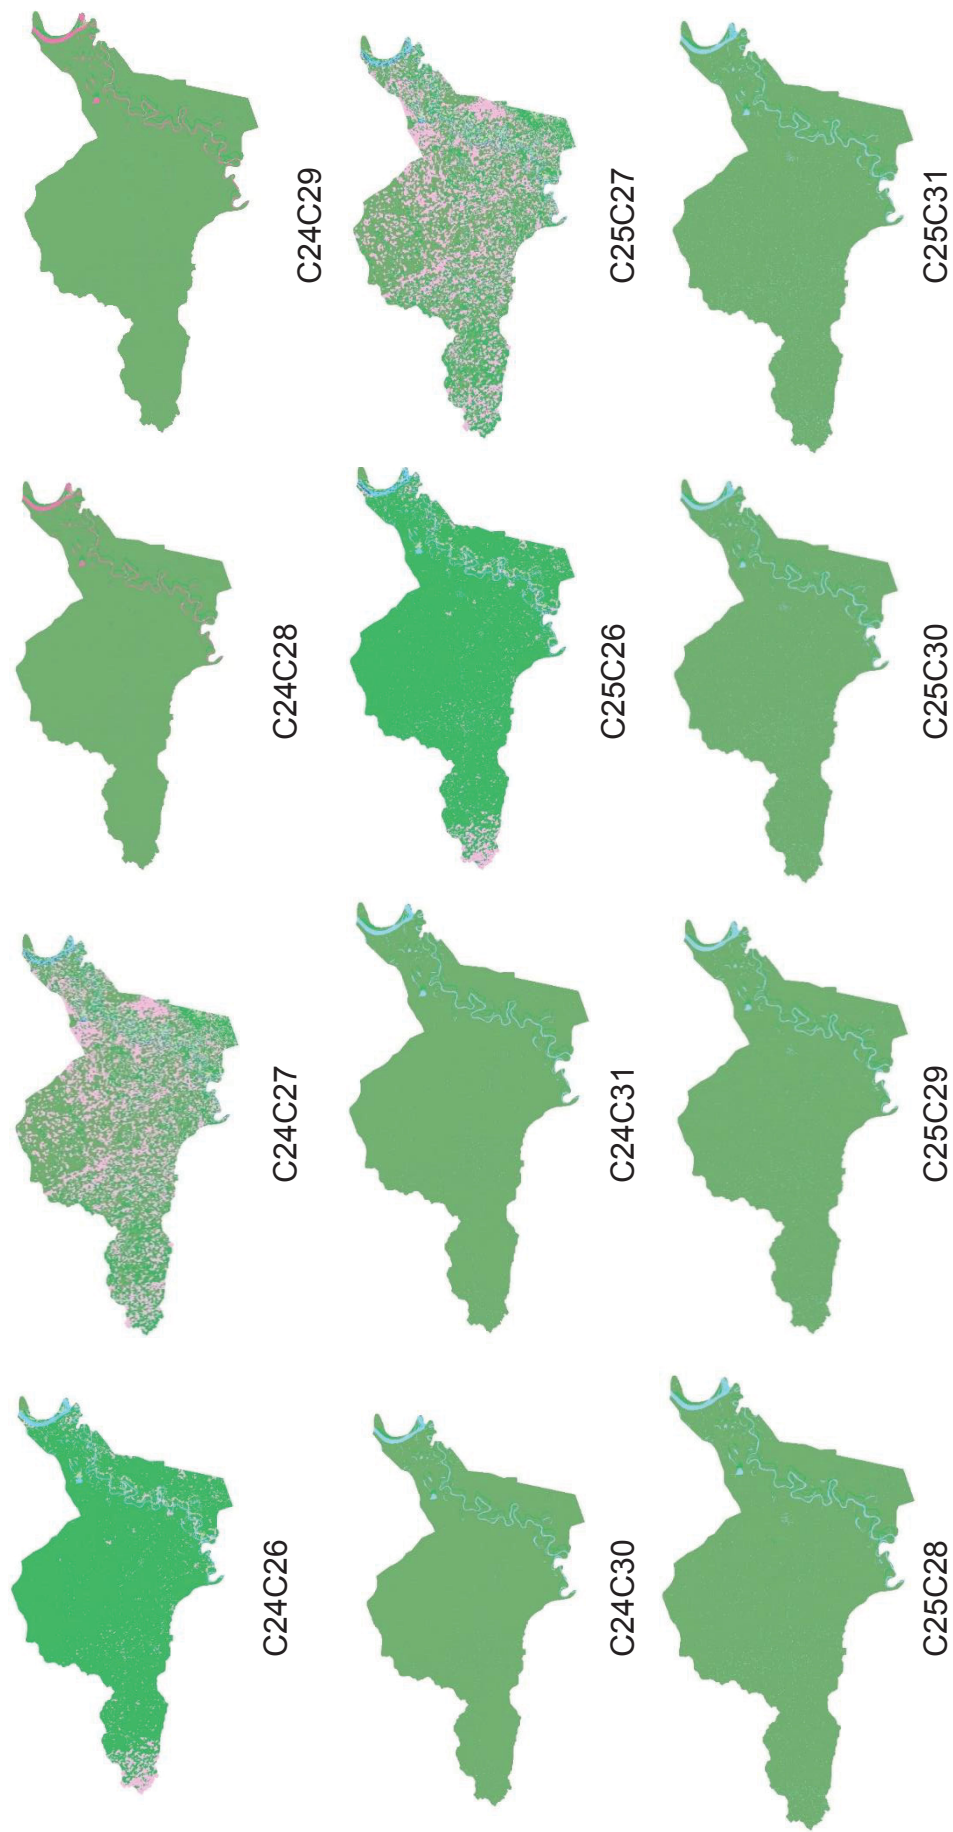


FUENTE: La autora (2019).

Fueron generadas 36 clasificaciones de cambio de uso de la tierra para los años 2015 y 2019 del modelo 2 (FIGURA 28).

FIGURA 28 - CAMBIO DE USO DE LA TIERRA MODELO 2






Continuación FIGURA 28



C32C26



C32C27



C32C28




C32C29




C32C30



C32C31



C33C26



C33C27



C33C28



C33C29



C33C30



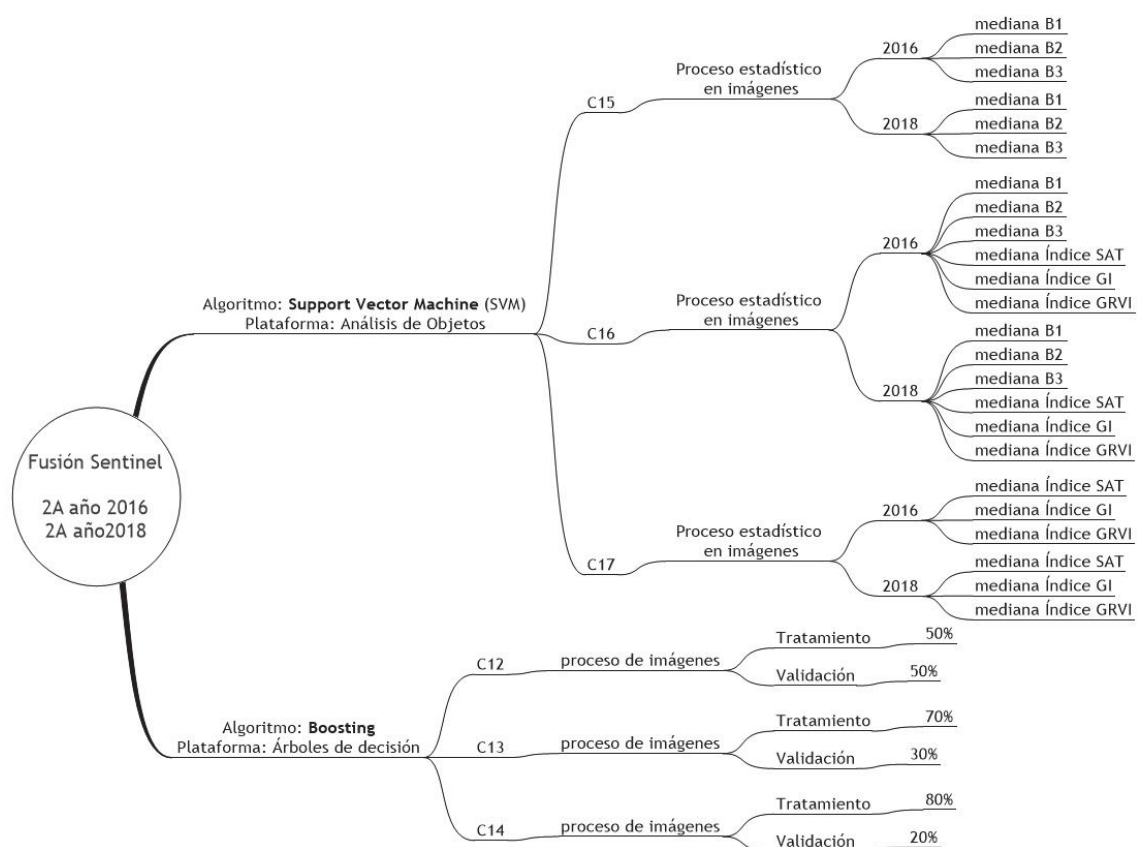
C33C31

Continuación FIGURA 28
FUENTE: La autora (2019).

4.1.3.1.3 Modelo 3

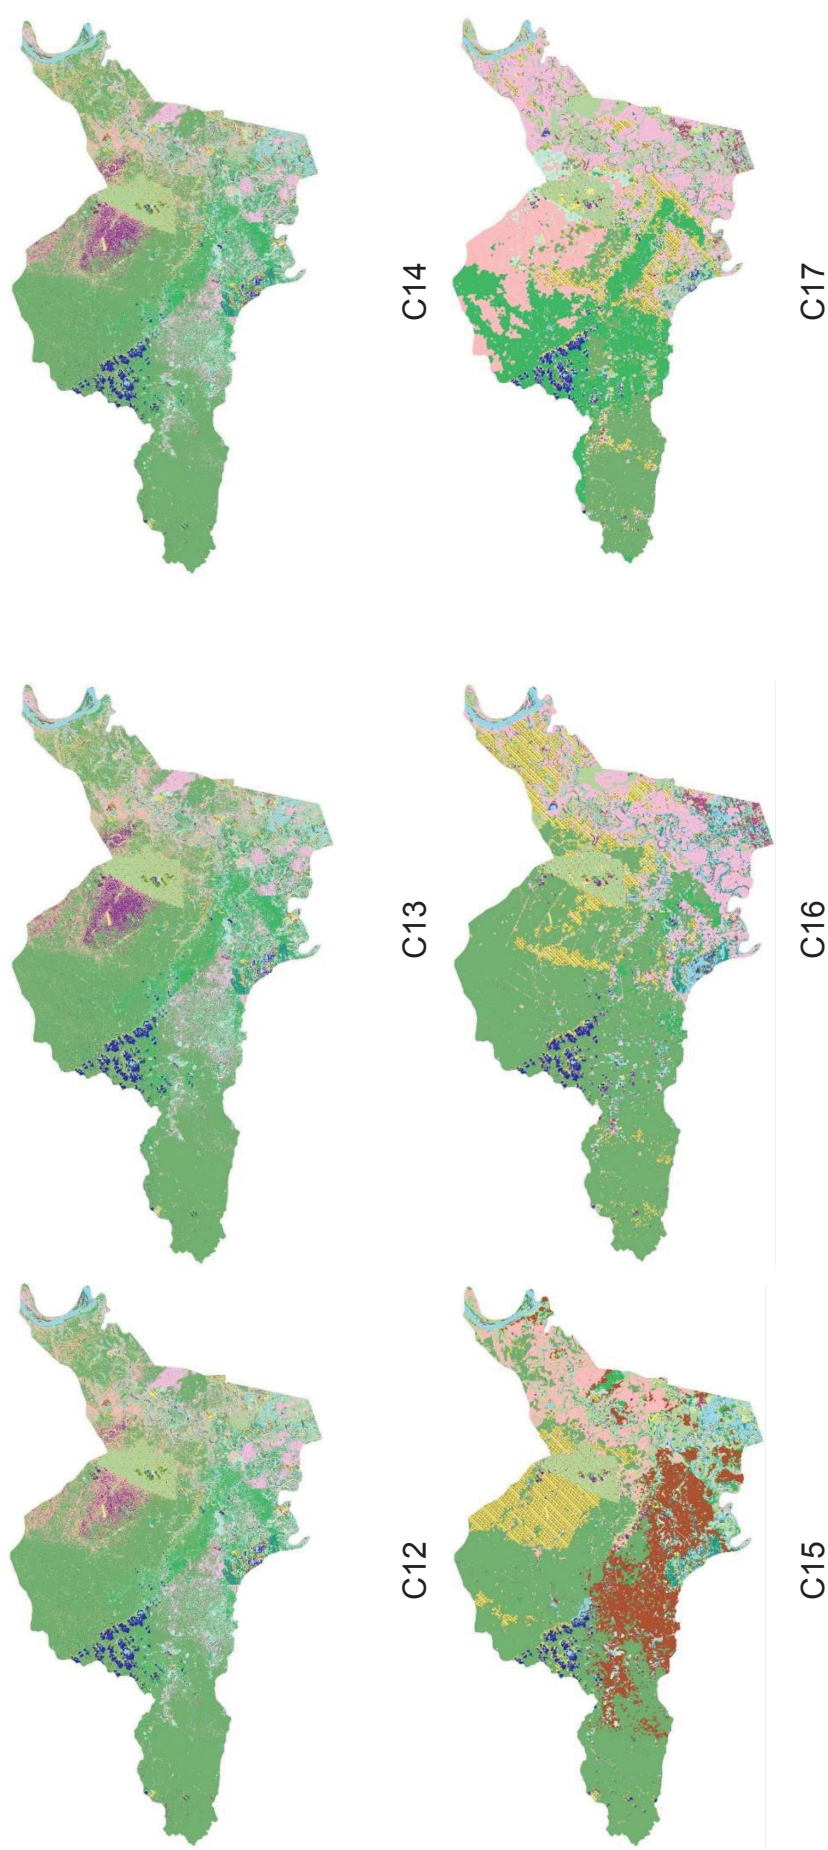
La clasificación se realizó sobre la fusión de los mosaicos de sensores pasivos, brindando directamente el resultado de cambio de uso de la tierra (FIGURA 29 y FIGURA 30).

FIGURA 29 - MODELO 3 - FUSIÓN DE MOSAICO 2016 Y 2018



FUENTE: La autora (2019).

FIGURA 30 - CAMBIO DE USO DE LA TIERRA MODELO 3



FUENTE: La autora (2019).

4.1.3.1.4 Modelo 4

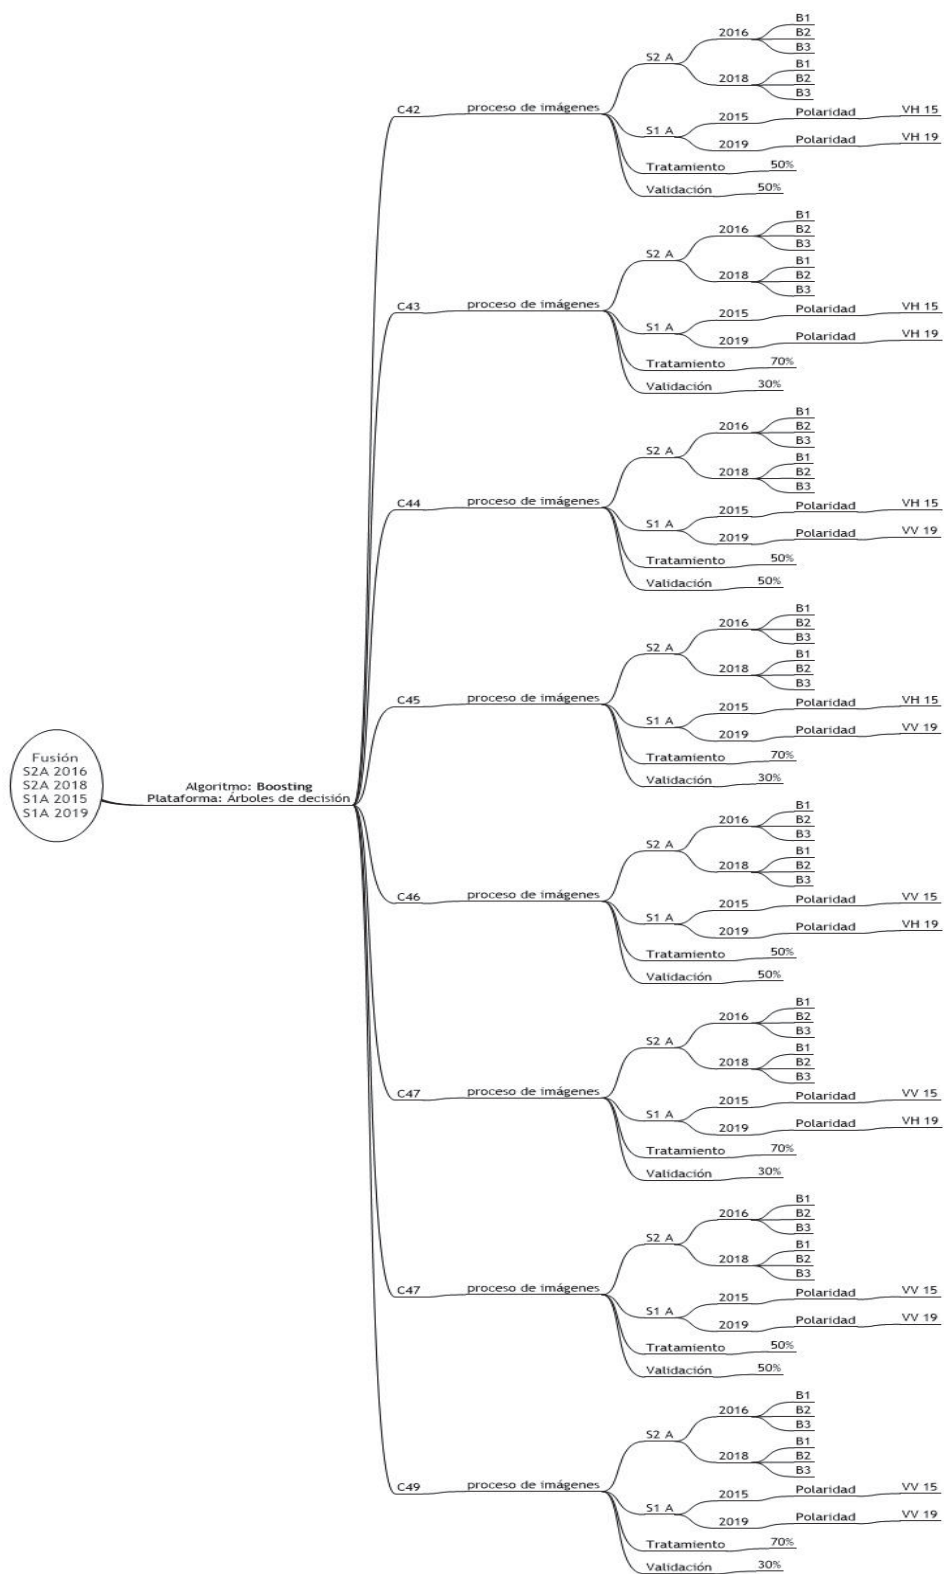
La clasificación se realizó sobre la fusión de los mosaicos de sensores pasivos y las imágenes activas; el resultado de la clasificación de cambio de uso de la tierra es obtenido directamente (FIGURA 31, FIGURA 32 y FIGURA 33).

FIGURA 31 - MODELO 4 – *SUPPORT VECTOR MACHINE (SVM)*




FUENTE: La autora (2019).

FIGURA 32 - MODELO 4 - BOOSTING




FUENTE: La autora (2019).


FIGURA 33 - CAMBIO DE USO DE LA TIERRA MODELO 4




C34




C35




C36




C37




C38




C39




C40




C41




C42




C43




C44




C45




C46



C47



C48



C49

Continuación FIGURA 33
FUENTE: La autora (2019).

4.1.4 Post-Procesamiento

Los resultados se revisaron los códigos de los atributos y se recodificó en el modelo 1 y el modelo 2, basado en la clave de identificación del cambio de uso de la tierra (véase TABLA 19) por dar resultado clasificaciones independientes que se unieron para tener de resultado el cambio de uso de la tierra para los períodos de estudio. Este paso no se realizó en los modelos 3 y 4 ya que el resultado de cambio de uso es directo por tener como insumo las imágenes fusionadas.

Se asignó su identificador de acuerdo a lo deseado se agrupó por clases, con este resultado se calculó la superficie de la mejor clasificación de cambio de uso de la tierra.

4.1.5 Análisis Estadístico

4.1.5.1 Resultado del Modelo 1

Con los mosaicos de las imágenes satelitales de los años 2016 y 2018 y los insumos: mediana de bandas espectrales, índice GI, GRVI y SAT, particiones de la muestra de 50 %,50%; 70%,30% y 80%,20% se obtuvieron las siguientes tasas de errores de clasificación (TABLA 25). El análisis completo se puede observar en el ANEXO 14.

TABLA 25 - TASA DE ERROR DEL MODELO 1

	Clasificación	Algoritmos usado	Tasa de Error
	Cambio de uso de la tierra		
MODELO 1 Imágenes satélites Sentinel-2A (2016 - 2018)	C1C7	SVM u SVM	81,5%
	C1C8	SVM u SVM	82,6%
	C1C9	SVM u SVM	84,0%
	C1C10	SVM u Boosting	99,9%
	C1C11	SVM u Boosting	99,8%
	C2C7	SVM u SVM	81,6%
	C2C8	SVM u SVM	80,0%
	C2C9	SVM u SVM	81,7%
	C2C10	SVM u Boosting	34,5%

C2C11	SVM u Boosting	31,7%
C4C7	Boosting u SVM	23,6%
C4C8	Boosting u SVM	24,0%
C4C9	Boosting u SVM	24,1%
C4C10	Boosting u Boosting	23,3%
C4C11	Boosting u Boosting	23,5%
C5C7	Boosting u SVM	25,3%
C5C8	Boosting u SVM	25,1%
C5C9	Boosting u SVM	25,1%
C5C10	Boosting u Boosting	23,6%
C5C11	Boosting u Boosting	23,9%
C6C7	Boosting u SVM	22,7%
C6C8	Boosting u SVM	26,1%
C6C9	Boosting u SVM	26,4%
C6C10	Boosting u Boosting	23,7%
C6C11	Boosting u Boosting	24,1%

FUENTE: La autora (2019).

Continuación TABLA 25

Las clasificaciones con menor tasa de error (menor a 30 %) son las que se evaluaron para determinar el mejor modelo. La clasificación C6C7 (algoritmo *boosting* con partición de la muestra 80%,20% (entrenamiento y prueba, respectivamente); insumo tres bandas espectrales del año 2016 y C7: algoritmo *Support Vector Machine* (SVM) e insumos de las medianas de las tres bandas del año 2018) presenta el menor error de clasificación para todo el modelo 1 siendo este de 22.7%. Las clasificaciones C4, C5 y C6 del año 2016 con tratamiento con el algoritmo *boosting* tienen errores de clasificación similares. Las clasificaciones C8 y C9 del año 2018 presentan mayor error de clasificación, habiendo sido clasificados con el algoritmo *Support Vector Machine* (SVM).

4.1.5.2 Resultado del Modelo 2

Con las imágenes de RADAR de los años 2015 y 2019 y con los insumos: diferentes polaridades de cada año, particiones de la muestra de 50%,50% y 70%,30% se obtuvieron las tasas de errores de clasificación mostradas en la Tabla 26. El análisis completo se puede observar en el ANEXO 15.

TABLA 26 - TASA DE ERROR DEL MODELO 2

	Clasificación Cambio de uso de la tierra	Algoritmos usado	Tasa de Error
MODELO 2 Imágenes RADAR Sentinel-1A (2015-2019)	C2226	SVM u SVM	93,3%
	C2227	SVM u SVM	83,8%
	C2228	SVM u Boosting	78,1%
	C2229	SVM u Boosting	77,7%
	C2230	SVM u Boosting	77,1%
	C2231	SVM u Boosting	76,8%
	C2326	SVM u SVM	81,1%
	C2327	SVM u SVM	83,5%
	C2328	SVM u Boosting	78,6%
	C2329	SVM u Boosting	78,3%
	C2330	SVM u Boosting	78,3%
	C2331	SVM u Boosting	78,2%
	C2426	Boosting u SVM	65,4%
	C2427	Boosting u SVM	59,3%
	C2428	Boosting u Boosting	60,1%
	C2429	Boosting u Boosting	60,1%
	C2430	Boosting u Boosting	60,1%
	C2431	Boosting u Boosting	60,1%
	C2526	Boosting u SVM	65,8%
	C2527	Boosting u SVM	59,7%
	C2528	Boosting u Boosting	60,4%
	C2529	Boosting u Boosting	60,5%
	C2530	Boosting u Boosting	60,5%
	C2531	Boosting u Boosting	60,4%
	C3226	Boosting u SVM	65,4%
	C3227	Boosting u SVM	64,5%
	C3228	Boosting u Boosting	60,0%
	C3229	Boosting u Boosting	60,1%
	C3230	Boosting u Boosting	60,1%
	C3231	Boosting u Boosting	60,0%
	C3326	Boosting u SVM	64,2%
	C3327	Boosting u SVM	59,3%
	C3328	Boosting u Boosting	60,5%
	C3329	Boosting u Boosting	60,5%
	C3330	Boosting u Boosting	60,5%
	C3331	Boosting u Boosting	60,5%

FUENTE: La autora (2019).

El uso de las imágenes de RADAR con sus diferentes polarizaciones y las diferentes particiones de la muestra, no provee la suficiente información para el análisis de cambio de uso de la tierra. Los porcentajes de errores de clasificación son muy altos, lo que no permite escoger un mejor modelo de clasificación.

4.1.5.3 Resultado del Modelo 3

Con los mosaicos de las imágenes satelitales de los años 2016 y 2018 fusionados y los insumos: mediana de bandas espectrales, índice GI, GRVI y SAT, particiones de la muestra de 50%,50% y 70%,30% se obtuvieron las tasas de errores de clasificación mostradas en la Tabla 27. El análisis completo se puede observar en el ANEXO 16.

TABLA 27 - ANÁLISIS ESTADÍSTICO DEL MODELO 3

	Clasificación	Algoritmo usado	%
			ERROR del Test
MODELO 3 Fusión de Imágenes Satelitales Sentinel-2A (2016 y 2018)	C12	Boosting	9,2%
	C13	Boosting	9,2%
	C14	Boosting	8,4%
	C15	SVM	10,7%
	C16	SVM	4,0%
	C17	SVM	6,2%

FUENTE: La autora (2019).

En el modelo 3 se muestra una tasa de error de clasificación entre 4% y 10,7%. Los modelos C12, C13 y C14 fueron clasificados con el algoritmo *boosting*, siendo el C14 (seis bandas espectrales con partición de la muestra de 80%,20%) el que presenta menor error de clasificación de este grupo (8,4%). En cuanto a los modelos C15, C16 y C17, clasificados con *Support Vector Machine* (SVM). La clasificación que presentó menor tasa de error de clasificación del modelo en mención fue el C16 (mediana de seis bandas y los índices GI, GRVI y SAT), con una tasa de error de clasificación de 4,0 %.

4.1.5.4 Resultado del Modelo 4

Con los mosaicos de las imágenes satelitales de los años 2016 y 2018, las imágenes de RADAR de los años 2015 y 2019 fusionados y los insumos: mediana de bandas espectrales, índice GI, GRVI y SAT, particiones de la muestra de 50 %,50%; 70%,30% y las diferentes polarizaciones, se obtuvieron las tasas de errores de clasificación mostradas en la Tabla 28. El análisis completo se puede observar en el ANEXO 17.

TABLA 28 - ANÁLISIS ESTADÍSTICO DEL MODELO 4

	Clasificación	Algoritmo usado	% ERROR del Test
MODELO 4 Fusión de Imágenes Satelitales-2A (2016 - 2018) Fusión Imágenes de RADAR-1 A (2015 - 2019)	C34	SVM	4,4%
	C35	SVM	4,4%
	C36	SVM	4,8%
	C37	SVM	7,7%
	C38	SVM	0,0%
	C39	SVM	4,8%
	C40	SVM	2,9%
	C41	SVM	9,9%
	C42	Boosting	8,5%
	C43	Boosting	8,7%
	C44	Boosting	8,7%
	C45	Boosting	8,7%
	C46	Boosting	8,7%
	C47	Boosting	7,8%
	C48	Boosting	8,7%
	C49	Boosting	7,6%

FUENTE: La autora (2019).

Los resultados de la clasificación de cambio de uso de la tierra para el modelo 4 muestran una tasa de error de clasificación entre 0% y 9,9%. El modelo C49 (partición de la muestra de 70 % entrenamiento y 30% de prueba para las seis bandas espectrales de las imágenes pasivas y polaridad VV para el año 2015 y VV

para el año 2019 de las imágenes activas), tratadas con el algoritmo *boosting*, presenta una tasa de error de clasificación de 7,6 % siendo la más baja para el grupo analizado con este algoritmo. En este modelo se observa que C38 presenta una tasa de error de clasificación de 0% siendo este resultado un resultado perfecto, lo que puede indicar que este modelo tiene problemas de sobreajuste. Por esto se seleccionó como mejor modelo del modelo 4 al C40 (algoritmo SVM, seis bandas espectrales, GI, GRVI, SAT, Polaridad VH año 2015 y VV año 2019) con 2.9% de tasa de error de clasificación.

4.1.6 Validación del Mapa

La validación de las clasificaciones se realizó utilizándose las imágenes de PERUSAT-1, PLANET y fotografías aéreas (TABLA 29) obtenidas del sobrevuelo realizado en el 2018.

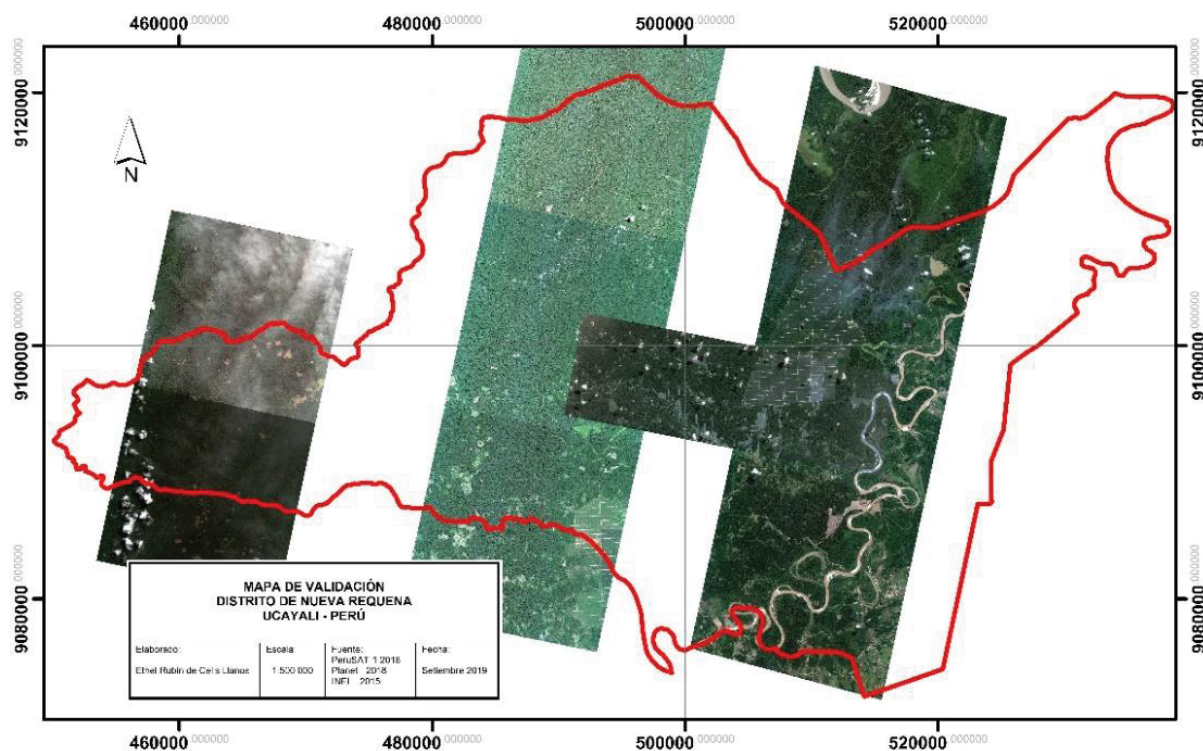
TABLA 29 - IMÁGENES SATELITALES DE VALIDACIÓN

Adquisición: Pedido a CNOIS por representante oficial de la UNALM			
Sensor	Fecha	Código original	R. Espacial
PerúSat1	Julio 2018	IMG_PER1_ORT_MS_000041	2,8 m
		IMG_PER1_20180712151937_ORT_MS_000041.TIF	
		IMG_PER1_20180814151704_ORT_MS_000041.TIF	
		IMG_PER1_20180902152016_ORT_MS_000041.TIF	
	Julio 2018	VOL_PER1_ORT_001_000659	2,8 m
		IMG_PER1_20180712151937_ORT_MS_000659.TIF	
		IMG_PER1_20180814151704_ORT_MS_000659.TIF	
		IMG_PER1_20180902152016_ORT_MS_000659.TIF	
	Set 2018	VOL_PER1_ORT_001_000670	2,8 m
	Julio 2018	IMG_PER1_20180902152016_ORT_MS_000670.TIF	2,8 m
		VOL_PER1_ORT_001_001277	
	Julio 2018	IMG_PER1_20180712151937_ORT_MS_001277.TIF	2,8 m
		IMG_PER1_20180814151704_ORT_MS_001277.TIF	
	Julio 2018	VOL_PER1_ORT_001_001470	2,8 m
	Agos 2018	IMG_PER1_20180712151937_ORT_MS_001470.TIF	2,8 m
		VOL_PER1_ORT_001_001882	2,8 m
		IMG_PER1_20180814151704_ORT_MS_001882.TIF	
Adquisición: Donación de ACCA			
Sensor	Fecha	Código original	R. Espacial
PLANET	Julio 2018	20180725_144756_1006_3B_AnalyticMS	4 m
Adquisición: Sobrevuelo para toma de fotografías aéreas			
Sensor	Fecha	Código original	R. Espacial
Fotos aéreas	Agosto 2018	100 fotografías aéreas divididas en 13 subproyectos	0,40m

FUENTE: La autora (2019).

Las imágenes satelitales de PERUSAT 1 - que se distribuyen gratuitamente por el CNOIS a representantes oficializados y a instituciones nacionales - fueron utilizadas para elaborar el mosaico para las 9 escenas y 1 escena de PLANET a pesar que el mosaico no cubre completamente el área de estudios (FIGURA 34).

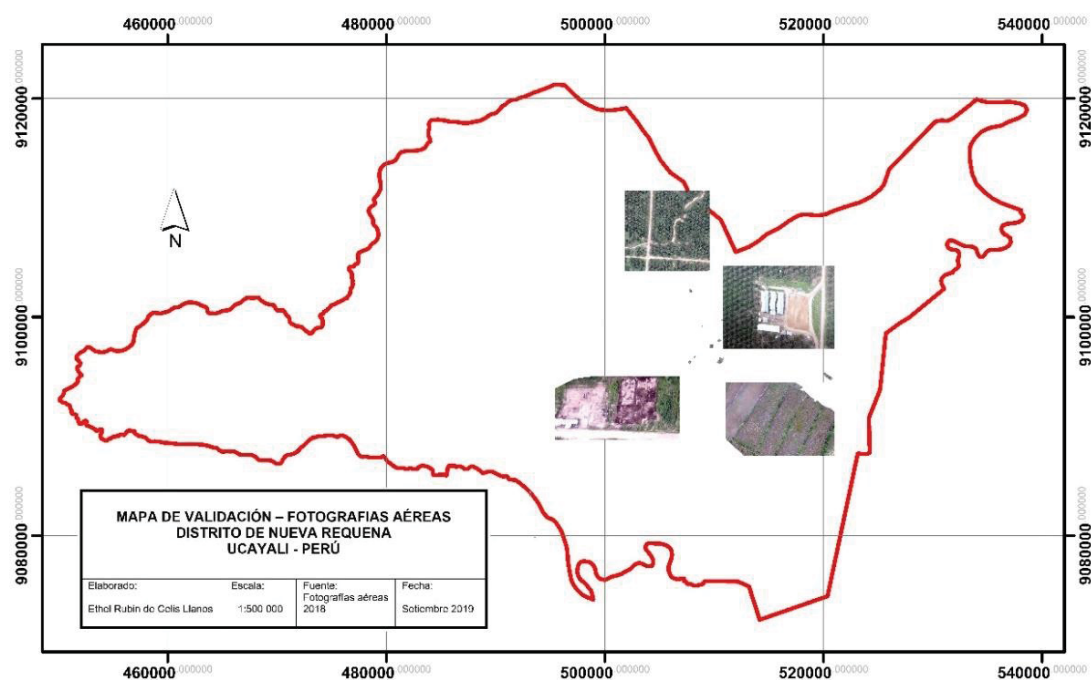
FIGURA 34 - MAPA DE IMÁGENES DE ALTA RESOLUCIÓN USADAS EN LA VALIDACIÓN 2018



FUENTE: La autora (2019).

Fueron también usadas fotografías aéreas generadas de un sobrevuelo realizado en el 2018 (FIGURA 35) (ANEXO 18).

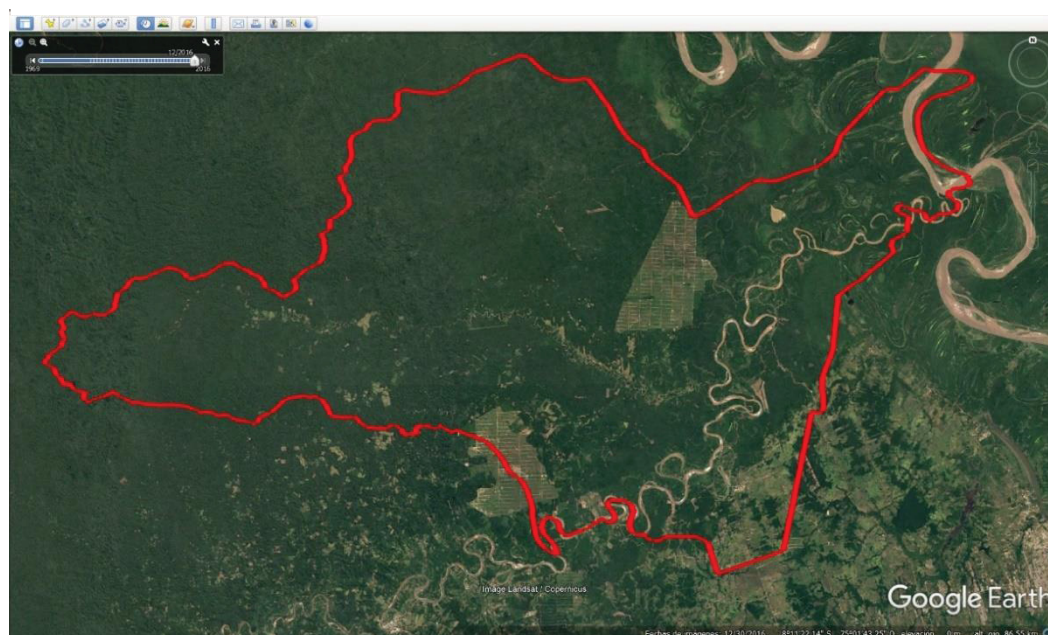
FIGURA 35 - MAPA DE FOTOGRAFÍAS AÉREAS USADAS EN LA VALIDACIÓN 2018



FUENTE: La autora (2019).

Por medio de las imágenes de Google Earth del año 2016 de acceso libre cubre por completo el distrito de Nueva Requena fue usado para validar el año 2016 (FIGURA 36).

FIGURA 36 - IMAGEN GOOGLE EARTH 2016 USADAS EN LA VALIDACIÓN 2016



FUENTE: Google Earth (2019).

4.1.6.1 Puntos de validación

Los puntos de validación se generaron para el distrito de Nueva Requena cubrieron totalmente las imágenes de referencia del 2018 puesto estas imágenes no cubrían totalmente al distrito de Nueva Requena. El número de puntos para validar fue de 5095. En la FIGURA 37 se muestran los puntos de validación.



FUENTE: La autora (2019).

Cada punto fue evaluado de acuerdo a lo que se observaba en las imágenes de alta resolución del año 2018 de igual manera se realizó para el año 2016 asignándole el atributo según la leyenda planteada en el estudio y evaluando cada modelo realizado. La clase nubes y sombra de nubes del año 2016 y la clase bosques del año 2018, en el análisis de validación se asumió la clase nube y sombra de nubes como bosque. Los resultados de la validación de cada modelo se muestran en las TABLAS 30, 31, 32 y 33; los nombres de cada clasificación se pueden observar en las FIGURAS 24, 26, 27, 29, 31 y 32. Por último, se determinó la fuerza de concordancia para cada validación.

TABLA 30 - ÍNDICE KAPPA Y PCC DEL MODELO 1

Análisis												
Estadístico/Clasificación		C1C7	C1C8	C1C9	C1C10	C1C11	C2C7	C2C8	C2C9	C2C10	C2C11	
2016	Kappa	0.537	0.53	0.538	0.53	0.53	0.606	0.511	0.534	0.515	0.513	
	Z	52.40	51.70	52.50	52.20	52.20	56.30	52.70	51.50	53.00	52.80	
	PCC	0.820	0.817	0.820	0.816	0.816	0.861	0.799	0.811	0.800	0.800	
2018	Kappa	0.547	0.577	0.499	0.504	0.516	0.56	0.577	0.551	0.533	0.514	
	Z	51.400	53.700	48.400	47.100	47.600	51.900	53.700	51.500	48.700	47.500	
	PCC	0.815	0.826	0.788	0.792	0.801	0.822	0.826	0.816	0.808	0.799	

Análisis												
Estadístico/Clasificación		C4C7	C4C8	C4C9	C4C10	C4C11	C5C7	C5C8	C5C9	C5C10	C5C11	
2016	Kappa	0.607	0.606	0.607	0.612	0.608	0.576	0.492	0.514	0.593	0.492	
	Z	56.500	56.200	56.400	56.800	56.300	54.000	48.500	50.100	55.700	48.500	
	P	0.861	0.861	0.861	0.863	0.862	0.846	0.797	0.812	0.855	0.797	
2018	Kappa	0.349	0.576	0.551	0.528	0.523	0.561	0.577	0.541	0.516	0.516	
	Z	52.200	53.700	51.400	48.500	48.500	51.900	53.800	50.600	47.400	47.900	
	P	0.717	0.825	0.816	0.807	0.805	0.823	0.826	0.812	0.801	0.801	

Análisis												
Estadístico/Clasificación		C6C7	C6C8	C6C9	C6C10	C6C11						
2016	Kappa	0.607	0.569	0.607	0.597	0.488						
	Z	56.100	53.500	56.000	55.700	48.500						
	P	0.861	0.842	0.861	0.856	0.795						
2018	Kappa	0.562	0.577	0.551	0.52	0.514						
	Z	51.900	53.800	51.400	48.000	47.400						
	P	0.823	0.826	0.816	0.802	0.801						

FUENTE: La autora (2019).

Las validaciones del modelo 1 muestran una fuerza de concordancia según el índice Kappa: Moderado (100%) del año 2016; Moderado (96%) y Aceptable (4%) del año 2018. Siendo la clasificación C6C7 (C6: algoritmo *boosting* con partición de la muestra 80% entrenamiento y 20% de prueba en tres bandas espectrales del año 2016; C7: algoritmo *Support Vector Machine* (SVM) con insumos de las medianas de las tres bandas del año 2018. Esta clasificación presenta el mejor índice Kappa 0,607 para el año 2016 y 0,562 para el año 2018; teniendo una fuerza de concordancia moderada, una tasa de error de clasificación de 22,7% y un PCC de 86,10% para el año 2016 y 82,30% para el 2018.

TABLA 31 - INDICE KAPPA Y PCC DEL MODELO 2

Análisis													
Estadístico/Clasificación		C22C26	C22C27	C22C28	C22C29	C22C30	C22C31	C23C26	C23C27	C23C28	C23C29	C23C30	C23C31
		Kappa	0.239	0.24	0.239	0.239	0.239	0.205	0.204	0.0346	0.205	0.205	0.205
2016	Z	21.900	21.900	21.900	21.900	21.900	21.900	19.200	19.100	5.970	19.200	19.200	19.200
	PCC	0.665	0.666	0.665	0.665	0.665	0.665	0.658	0.658	0.776	0.658	0.658	0.658
	Kappa	0.002	0.069	0.025	0.024	0.013	0.012	0.002	0.070	0.023	0.023	0.014	0.013
2018	Z	1.260	10.000	4.410	4.660	2.840	2.600	1.150	10.100	3.990	4.370	2.930	2.690
	PCC	0.180	0.389	0.750	0.751	0.750	0.750	0.180	0.389	0.749	0.751	0.750	0.750

Análisis													
Estadístico/Clasificación		C24C26	C24C27	C24C28	C24C29	C24C30	C24C31	C25C26	C25C27	C25C28	C25C29	C25C30	C25C31
		Kappa	0.077	0.079	0.034	0.000	0.079	0.081	0.082	0.080	0.081	0.072	0.072
2016	Z	20.400	20.700	5.910	0.000	20.500	20.400	17.700	17.800	17.400	17.500	13.800	13.800
	PCC	0.780	0.784	0.772	0.778	0.784	0.780	0.774	0.774	0.774	0.774	0.764	0.764
	Kappa	0.002	0.069	0.023	0.018	0.013	0.012	-0.001	0.037	0.021	0.020	0.011	0.010
2018	Z	1.010	9.940	3.990	3.120	2.750	2.510	-0.310	8.250	3.890	4.030	2.380	2.270
	PCC	0.180	0.388	0.749	0.748	0.750	0.750	0.167	0.323	0.736	0.737	0.736	0.736

Análisis													
Estadístico/Clasificación		C32C26	C32C27	C32C28	C32C29	C32C30	C32C31	C33C26	C33C27	C33C28	C33C29	C33C30	C33C31
		Kappa	0.077	0.082	0.077	0.077	0.074	0.072	0.083	0.082	0.083	0.082	0.082
2016	Z	20.200	17.800	20.100	20.100	20.100	17.600	13.800	18.000	17.600	17.700	17.600	17.600
	PCC	0.780	0.774	0.780	0.780	0.780	0.776	0.764	0.778	0.778	0.778	0.778	0.778
	Kappa	-0.001	0.055	0.021	0.021	0.012	0.010	0.002	0.069	0.023	0.022	0.012	0.011
2018	Z	-0.310	8.140	3.810	4.140	2.610	2.270	1.150	9.930	4.070	4.190	2.510	2.270
	PCC	0.167	0.375	0.736	0.737	0.737	0.736	0.180	0.388	0.749	0.750	0.750	0.749

FUENTE: La autora (2019).

En el modelo 2, la fuerza de concordancia según los resultados del índice Kappa para el año 2016 es Leve (66,6%), Aceptable (30,55%) y Pobre (2,78%) y para el año 2018 el índice Kappa fue Pobre (16,67%) y Leve (83,33%) mostrando una concordancia inadecuada para la clasificación de uso de la tierra. Esto corrobora los resultados de la tasa de error de clasificación.

TABLA 32 - ÍNDICE KAPPA Y PCC DEL MODELO 3

Análisis							
Estadístico/Clasificación		C12	C13	C14	C15	C16	C17
2016	Kappa	0.415	0.425	0.418	0.333	0.475	0.531
	Z	43.300	45.300	44.600	40.300	51.400	52.500
	PCC	0.774	0.778	0.774	0.665	0.802	0.827
2018	Kappa	0.351	0.35	0.348	0.452	0.436	0.151
	Z	39.900	39.900	39.900	49.400	49.600	24.000
	PCC	0.652	0.652	0.648	0.738	0.729	0.384

FUENTE: La autora (2019).

En el modelo 3 se observa una fuerza de concordancia para el año 2016 Aceptable (16,67%) y Moderada (83,33 %) para el año 2018 presenta una fuerza de concordancia Leve (20%), Aceptable (60%) y Moderada (20 %). A su vez, se observa que todas las clasificaciones que tienen como insumo las seis bandas espectrales tienen un PCC mayor a 60%. La clasificación con mejor índice Kappa es C16 (algoritmo *Support Vector Machine* (SVM) que tiene como insumos las medianas de las bandas espectrales de cada año como las medianas de los índices SAT, GI, GRVI) con 0,475 para el año 2016 y 0,436 para el año 2018 con una PCC de 80.205 para el año 2016 y 72.90 % para el año

TABLA 33 - ÍNDICE KAPPA Y PCC DEL MODELO 4

Análisis Estadístico/Clasificación		C34	C35	C36	C37	C38	C39	C40	C41
2016	Kappa	0.267	0.366	0.394	0.414	0.494	0.492	0.503	0.5
	Z	38.100	44.400	47.200	47.900	52.800	51.400	53.200	53.500
	PCC	0.673	0.721	0.729	0.754	0.813	0.813	0.814	0.815
2018	Kappa	0.359	0.396	0.371	0.386	0.453	0.383	0.386	0.363
	Z	42.300	45.800	46.200	45.100	50.000	46.400	47.400	44.800
	PCC	0.702	0.689	0.663	0.682	0.737	0.664	0.679	0.657

Análisis Estadístico/Clasificación		C42	C43	C44	C45	C46	C47	C48	C49
2016	Kappa	0.417	0.423	0.407	0.437	0.428	0.279	0.427	0.439
	Z	43.900	44.900	43.500	45.900	45.400	44.500	44.800	45.900
	PCC	0.779	0.781	0.766	0.783	0.778	0.542	0.780	0.787
2018	Kappa	0.359	0.363	0.362	0.353	0.375	0.359	0.358	0.358
	Z	40.500	41.100	41.200	39.600	42.500	40.200	40.700	40.800
	PCC	0.660	0.662	0.659	0.654	0.668	0.660	0.655	0.653

FUENTE: La autora (2019).

Según los resultados, los índices Kappa del modelo 4, presentan una fuerza de concordancia para el año 2016 Aceptable (25%) y Moderada (75%) y para el año 2018 Aceptable (93,75%) y Moderada (6,25%). El C38 presenta un índice Kappa moderada y una tasa de error de clasificación de 0%, pudiendo ser por un error de sobreajuste, descartándolo como mejor clasificación de este modelo. Comparando los resultados de validación, el C40 (algoritmo SVM con las medianas de las seis bandas de las imágenes satelitales y medianas de los índices SAT, GI GRVI, polarización VV del año 2015 y VH del año 2019) es el modelo que presenta mejores indicadores siendo el valor del índice Kappa de 0,50 para el año 2016 y 0,30 para el año 2018 con un PCC de 81,40% para el año 2016 y 67,9% para el año 2018, esta clasificación presenta una tasa de error de clasificación de 2,9 %, siendo este el mejor modelo del modelo 4.

4.1.6.2 Matriz de confusión

Mediante la matriz de confusión se identificaron los errores de comisión y omisión según el resultado de la evaluación de clasificación para todas las clases de cambio de uso de la tierra. Las TABLAS 34 y 35 muestra la matriz de confusión del modelo 1.

TABLA 34 - MATRIZ DE CONFUSIÓN C6 AÑO 2016

Clase de uso de la tierra	1	2	3	4	5	6	Total	Exactitud %	Error Omisión %
1	3799	115	4	28	1	13	3960	95,93	4,07
2	145	518	19	33	41	37	793	18,28	81,72
3	99	45	3	6	1	2	156	63,46	36,54
4	20	51	0	62	7	1	141	14,18	85,82
5	10	5	0	2	2	0	19	52,63	47,37
6	10	12	0	1	0	3	26	38,46	61,54
Total	4083	746	26	132	52	56	5095		
Exactitud %	93,04	69,44	11,54	46,97	3,85	5,36		Precisión	
%Error Comisión	6,96	30,56	88,46	53,03	96,15	94,64		global del mapa	86,10 %

FUENTE: La autora (2019).

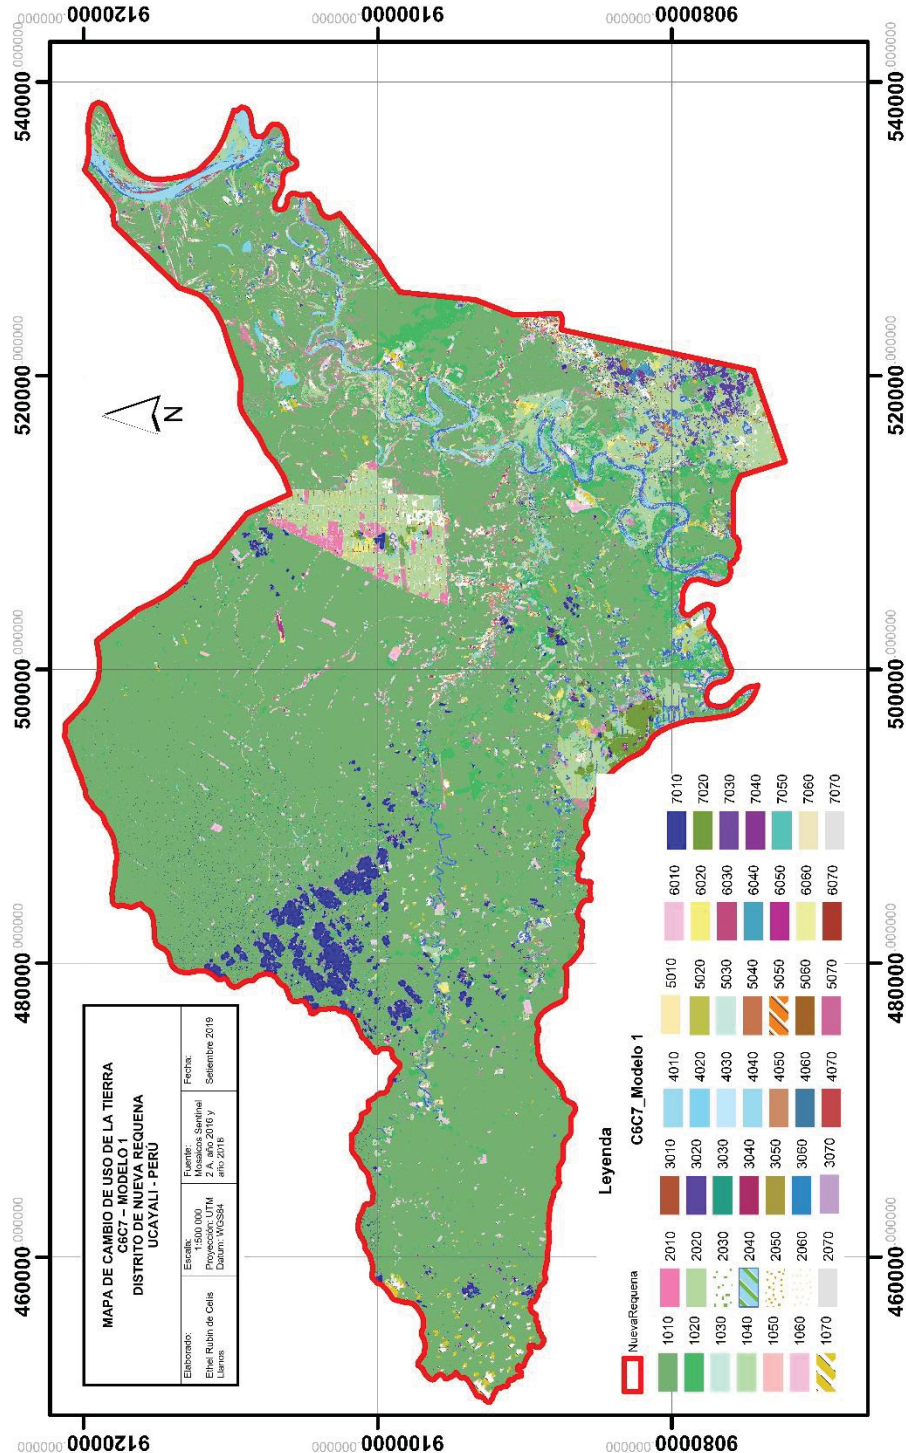
TABLA 35 - MATRIZ DE CONFUSIÓN C7 AÑO 2018

Clase de uso de la tierra	1	2	3	4	5	6	Total	Exactitud %	Error Omisión %
1	3526	249	4	13	10	25	3827	92,13	7,87
2	202	570	24	16	60	35	907	22,27	77,73
3	53	70	3	6	2	13	147	36,05	63,95
4	3	41	0	67	8	2	121	2,48	97,52
5	10	7	0	2	7	0	26	38,46	61,54
6	14	18	1	8	7	19	67	20,90	79,10
Total	3808	955	32	112	94	94	5095		
Exactitud %	92,59	59,69	9,38	59,82	7,45	20,21		Precisión	
%Error Comisión	7,41	40,31	90,63	40,18	92,55	79,79		global del mapa	82,30%

La realización de las matrices de confusión fue parte de la validación y análisis de la certeza de que las clases sean las correctas entre lo clasificado y la referencia.

La mejor clasificación se presenta en el modelo 1 en la clasificación C6C7 cuyo mapa se muestra en la FIGURA 38.

FIGURA 38 - MAPA DE LA CLASIFICACIÓN C6C7 – MODELO 1



FUENTE: La autora (2019).

5 CONCLUSIONES Y RECOMENDACIONES

- Considerando el caso específico del distrito de Nueva Requena, provincia de Coronel Portillo, departamento de Ucayali, Perú o zonas amazónicas similares, se requiere trabajar las imágenes satelitales pasivas en forma separada para obtener una clasificación supervisada con menor tasa de error de clasificación y una validación aceptable a moderada.
- Los mejores insumos que aportan a una mejor clasificación supervisada son: las bandas espectrales de la imagen satelital del sensor pasivo para cada año de estudio.
- El algoritmo *Support Vector Machine* (SVM) y *Boosting* en la clasificación supervisada, interactuando en el álgebra de mapas da el modelo más adecuado para determinar el cambio de uso de la tierra en el distrito de Nueva Requena.
- La validación de los modelos es conveniente y necesaria realizarlo para ambos años de análisis y la tasa de error de clasificación es un indicador que cuantifica la frecuencia de mala clasificación en la muestra, pero no determina por sí solo cual es el mejor modelo para el clasificador supervisado. Se recomienda como criterio un índice Kappa ubicado en Moderado y un PCC mayores al 60% para determinar el mejor modelo.
- El mejor modelo de clasificación supervisada de cambio de uso de la tierra, fue el que resultó al utilizar imágenes pasivas clasificadas en forma separada y con los algoritmos *Support Vector Machine* (SVM) y *Boosting*. Los insumos fueron las bandas espectrales del visible de las imágenes pasivas El índice Kappa debe ubicarse en el rango de moderado y PCC mayor al 60% con una tasa de error de clasificación menor al 10%.

De acuerdo a lo obtenido se recomienda:

- Para próximos trabajos de análisis de cambio de uso de la tierra deben incluirse las variables de bandas infrarrojas, filtros con las imágenes de RADAR, índices relacionados con la vegetación, entre otros.
- Tener mucho cuidado en la asignación de las áreas de entrenamiento, puesto

que es la parte sensible de la clasificación supervisada con sensores remotos, en especial cuando se usan algoritmos de inteligencia artificial.

- Un monitoreo de las zonas en diferentes épocas, anual o mensual puede contribuir a tener mayor cantidad de insumos para verificar y utilizar mejor un modelo de clasificación, dando así, mejores resultados en la clasificación de cambio de uso de la tierra.
- Probar con otros algoritmos de inteligencia artificial las clasificaciones de cambio de uso de la tierra para verificar su potencial e idoneidad en este tema.

REFERENCIAS BIBLIOGRÁFICAS

ANGELINI, M. **Clasificación digital de imágenes satelitales**. Revista de Teledetección, (3), 1–10. Canadá, 2016. Disponible en: <http://ecaths1.s3.amazonaws.com/geomatica/289121082.m1-LECTURA6-CLASIFICACION.pdf>. Consultado 20 dic 2018.

BARRENA, V., RUBIN DE CELIS, E., GUILLÉN, R., PONCE, B., O'BRIEN, E., HUAMANÍ, J., & FERNÁNDEZ, J. **Monitoreo-Deforestacion-por-Palma-I y II**. Lima-Perú, 2014. Disponible en: <https://maaproject.org/2015/imagen-4-proyectos-de-aceite-de-palma-deforestan-el-bosque-primario-de-la-amazonia-peruana-primera-parte-nueva-requena/>. Consultado 20 marzo 2018.

BASTERRA, INDIRA. **Teledetección-imágenes satelitales-procesamiento digital de imágenes**. Cátedra de fotointerpretación - Departamento de Geociencias Facultad de Ingeniería de la Universidad Nacional del Nordeste. Argentina, 2011.

BRONDÍZIO, E. **Agriculture Intensification, Economic Identity, and Shared Invisibility in Amazonian Peasantry: Caboclos and Colonists in Comparative Perspective**. In **Classical Antiquity** (Vol. 26, pp. 181–214). Department of Anthropology, Indiana University, Bloomington, IN, USA, 2009. https://doi.org/10.1007/978-1-4020-9283-1_9.

CCRS. CENTRO CANADIENSE DE PERCEPCIÓN REMOTA, 2005. Disponible en: <https://www.nrcan.gc.ca/science-data/science-research/earth-sciences/10774>. Consultado 20 noviembre 2019.

CERDA LORCA, J., & VILLARROEL DEL P., L. **Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa**. Revista Chilena de Pediatría, 79(1), 54–58. Chile, 2008. <https://doi.org/10.4067/s0370-41062008000100008>. Consultado 10 ene 2018.

CHUVIECO, E. **Fundamentos de Teledetección Espacial** (Segunda Ed.). Madrid - España, 1990. <https://es.scribd.com/doc/55587962/LIBRO-FUNDAMENTOS-DE-TELEDETECCION-EMILIO-CHUVIECO>. Consultado 10 ene 2018.

CHUVIECO, E. **Procesamiento estándar de imágenes Landsat**. Documento técnico de algoritmos a aplicar. Madrid-España, 2010.

CNUCC. Convención de las Naciones Unidas Contra la Corrupción. **Informe de la Conferencia de las partes sobre su séptimo periodo de sesiones**. Segunda Parte. Medidas Adoptadas Por La Conferencia De Las Partes (Vol. 60225). Marrakech, Marruecos, 2002.

CONIDA. La Comisión Nacional de Investigación y Desarrollo Aeroespacial. Lima-Perú, 2016. Disponible en: <http://www.conida.gob.pe/index.php/noticias/perusat-1-satelite-de-observacion-de-la-tierra>. Consultado en octubre 2018.

CORDERO, D. **Los Bosques En América Latina**. Fundación Friedrich Ebert, FES-ILDIS, 24. Ecuador, 2011. Revisado desde http://www.portalces.org/sites/default/files/migrated/docs/los_bosques_en_america_latina_fes-ildis_2011.pdf . Consultado abril 2019.

DALE, V., & BEYELER, S. **Challenges in the development and use of ecological indicators**. Ecological Indicators, 1, 3–10. USA, 2001. Disponible en: [https://doi.org/10.1016/S1470-160X\(01\)00003-6](https://doi.org/10.1016/S1470-160X(01)00003-6). Consultado marzo 2019.

DEFENSORÍA DEL PUEBLO. **Adjuntía para la prevención de conflictos sociales y la gobernabilidad**. 1–120. Lima, Perú, 2019.

ERDAS (2008). ERDAS at Map Asia. Corporate News – Sensors & Systems. **Making Sense of Global Change**. USA, 2008. Revisado desde <https://sensorsandsystems.com/erdas-at-map-asia-2008/>. Consultado enero 2018.

ESAa. Agencia Espacial Europea. <https://www.esa.int/> . Actualizado en 2019. Consultado en junio 2019.

ESAb. European Space Agency. Características Técnicas de SENTINEL. Actualizado en 2019. Disponible en: www.esa/Sentinel.esa.int. Consultado julio 2019.

ESCOBAR-PÉREZ, J., & CUERVO-MARTÍNEZ, Á. **Validez de Contenido y Juicio de Expertos: Una Aproximación a su Utilización**. Avances en medición. Universidad El Bosque, Colombia, 2008. 27–36 p.

ESTRATEGIA NACIONAL SOBRE BOSQUES Y CAMBIO CLIMÁTICA. **Estrategia Nacional sobre Bosques y Cambio Climático**. Lima-Perú, 2016.

FAO. Organización de las Naciones Unidas para la Alimentación y la Agricultura. **FRA 2015 Implementación Plan**. Revisado desde <http://www.fao.org/3/ap863e.pdf>. Roma, Italia, 2012.

FAO. Organización de las Naciones Unidas para la Alimentación y la Agricultura. **State of the world's forests 2016. El Estado de los Bosques del Mundo 2016. Los Bosques y La Agricultura: Desafíos y Oportunidades en Relación con el Uso de la Tierra**. Roma, Italia, 2016. 119 p.

FAO. Organización de las Naciones Unidas para la Alimentación y la Agricultura. **Evaluación de los recursos forestales mundiales 2015 ¿Cómo están cambiando los bosques del mundo?** Segunda edición. Revisado desde www.fao.org/forest-resources-assessment/es. Roma, Italia (n/d).

FAO. Organización de las Naciones Unidas para la Alimentación y la Agricultura. **How to Feed the World in 2050**. Insights from an Expert Meeting at FAO. <https://doi.org/10.1111/j.1728-4457.2009.00312.x>. 2009.

FEARNSIDE, P.M., LAURANCE, W.F. **Tropical deforestation and greenhouse gas emissions**. Ecological Applications 14. Brasil, 2004. 982–986 p.

FRANCO-ARCEGA, A., CARRASCO-OCHOA, J. A., SÁNCHEZ-DÍAZ, G., & MARTÍNEZ-TRINIDAD, F. **Árboles de Decisión para Grandes Conjuntos de Datos**. México, 2013. 95-102 p.

GARCÍA FOMINAYA, J. A. P. D. M. **Nuevas técnicas de localización, clasificación e identificación para radares de vigilancia superficial y alta resolución en escenarios LPI**. Madrid, España, 2004.

GEIST, H. J., & LAMBIN, E. F. **Proximate Causes and Underlying Driving Forces of Tropical Deforestation**. BioScience Vol. 52 No 2. Oxford academic. [https://doi.org/10.1641/0006-3568\(2002\)052\[0143:pcaudf\]2.0.co;2](https://doi.org/10.1641/0006-3568(2002)052[0143:pcaudf]2.0.co;2). Inglaterra, 2002. 143p.

GEOBOSQUES. Ministerio del Ambiente. Estado Peruano. **Plataforma de monitoreo de los cambios sobre la cobertura de los bosques**. Lima, Perú, 2019. Disponible en: <http://geobosques.minam.gob.pe/geobosque/view/index.php> Consultado junio 2019.

GLOBE SAR. Curso: **Material educativo para teledetección mediante radares. GlobeSAR Program Canada Centre for Remote Sensing Natural Resources**. Ottawa, Canadá, 2012. Disponible en: http://www.ccrs.nrcan.gc.ca/ccrs/rd/programs/globsar/gsar2_e.html. Consultado agosto 2019.

GOBIERNO REGIONAL DE UCAYALI. Presupuesto y acondicionamiento territorial. **Plan de Desarrollo Regional Concertado del departamento de Ucayali al 2021**. Ucayali, Perú, 2015.

GÓMEZ DE LA TORRE, S., ANDA, S., & BEDOYA GARLAND, E. **Procesos políticos y estructurales de la deforestación en la Amazonía: el caso de Tena, Ecuador**. Espacio y Desarrollo, (29), 7–36. Ecuador, 2017. Disponible en: <https://doi.org/10.18800/espacioydesarrollo.201701.001>. Consultado febrero 2019.

GOOGLE EARTH. 2018. Disponible en: <https://www.google.com/intl/es/earth/>

HAINES-YOUNG, R. **Land use and biodiversity relationships. Land Use Policy**, Vol. 26. Cambridge, 2009. Disponible en: <https://doi.org/10.1016/j.landusepol.2009.08.009>. Consultado 2018.

HERNÁNDEZ PARDO, O. **Estudio tectónico y estructural a partir del monitoreo sísmico y anomalías de campos potenciales**. Universidad Nacional de Colombia, Departamento de Geociencias Facultad de Ciencias. Bogotá Colombia, 2009. Disponible en: http://www.anh.gov.co/Informacion-Geologica-y-Geofisica/Tesis/5_Informe_Final.pdf. Consultado enero, 2018.

HOFFMAN, M. AND GRIGERA, A. **Climate Change, Migration, and Conflict in the Amazon and the Andes. Rising Tensions and Policy Options in South America**. Center for American Progress, 2013.

IBM. International Business Machines Corporation. Madrid, 2018. Disponible en: https://www.ibm.com/support/knowledgecenter/es/SS3RA7_sub/modeler_mainhel_p_client_ddita/clementine/svm_howwork.html. Consultado en setiembre, 2018.

IGN. Instituto Geográfico Nacional. **Atlas del Perú**. Lima, 1989. 400 p.

INEI. Instituto Nacional de Estadística e informática del Perú. **Censo Nacional 2017: XII Población, VII de vivienda - UCAYALI**. Lima-Perú, 2018.

INPEa. Instituto Nacional Pesquisas Espaciales. <http://www.inpe.br>. Brasil, 2018. Consultado enero 2018.

INPEb. Instituto Nacional Pesquisas Espaciales. **Plataforma de PRODES, Programa Amazonia**. <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Brasil
Noviembre, 2019. Consultado junio 2019.

ISABEL DE ARQUER, M. **Fiabilidad humana: métodos de cuantificación, juicio de expertos**. Instituto Nacional de Seguridad e Higiene En El Trabajo, Ministerio de Trabajo y Asuntos Sociales, España, 1–5. 1994.

KENE. Instituto de Estudios Forestales y Ambientales. **Monitoreo de la deforestación en los distritos de Fernando Lores (Loreto) y Nueva Requena (Ucayali)**. Actualización al 2017.

LAMBIN, E. F., TURNER, B. L., GEIST, H. J., AGBOLA, S. B., ANGELSEN, A., BRUCE, J. W., XU, J. **The causes of land-use and land-cover change: Moving beyond the myths**. Global Environmental Change, Vol. 11, pp. 261–269. Elsevier Science, 2001. Disponible en: [https://doi.org/10.1016/S0959-3780\(01\)00007-3](https://doi.org/10.1016/S0959-3780(01)00007-3). Consultado en junio 2018.

LAURANCE, W. F., LAURANCE, S. G., & DELAMONICA, P. **Tropical forest fragmentation and greenhouse gas emissions. Forest Ecology and Management**, 110(1–3), 173–180 p. Elsevier Science, 1998. Disponible en: [https://doi.org/10.1016/S0378-1127\(98\)00291-6](https://doi.org/10.1016/S0378-1127(98)00291-6). Consultado en octubre 2017.

LEWIS, A.J. and HENDERSON, F.M. **Radar Fundamentals: The Geoscience Perspective**. In: Hendesron, F.M. and Lewis, A.J., Eds., Principles and Application of Imaging Radar: Manual of Remote Sensing, 3th Edition, Hendesron and Lewis, New York, 567-629. 1998. Consultado en octubre 2017

Ley N °29763. Ley Forestal y de Fauna Silvestre Lima - Perú. 2011.

Ley N ° 29763 Decreto Supremo 018-2015-MINAGRI.

Ley N ° 23099. Decreto Ley 23099. Creación del departamento de Ucayali, 1980.

Ley N ° 23416. Decreto Ley 23416. Creación de distrito de Nueva Requena. 1982.

LIRA CHÁVEZ, J. **Tratamiento digital de imágenes multispectrales** (2da Edición). Instituto de Geofísica, Universidad Nacional Autónoma de México, UNAM. México, D.F., 2010.

MAAP. Proyecto Monitoreo de la Amazonía Andina. Disponible en: <https://maaproject.org/es/>. Lima, Perú, 2015. Consultado Setiembre 2019.

MARTÍNEZ-VALLEJO P. ELIZABETH, MORENO-VALLEJO C. ALEXANDER, RENDÓN-CEDEÑO M. JOSÉ, RUIZ-SALVADOR, L. URDES CECILIA, SAMPEDRO-JARA M. CAROLINA, & SANTICUJ E. ORFA. **Análisis actual de la Amazonía ecuatoriana: ejes productivos, conservación y desafíos a futuro**. In / Biodivers. Amazon. Año (Vol. 5), 2015.

MATLAB®. **MATLAB User's Guide**, 2015. Disponible en: <https://la.mathworks.com/discovery/support-vector-machine.html>. Consultado Setiembre 2019.

MEHL, H.; MIES, E. **Aplicación de la Teledetección y de los sistemas de información geográfica en la gestión de los recursos naturales. Parte I: Fundamentos teóricos y prácticos**. Fundación Alemana para el Desarrollo Internacional (DSE). Feldafing, Alemania, 1997.

MENDOZA, R., & GIUDICE, R. **Análisis de la pérdida de cobertura forestal en comunidades nativas de la Amazonía del Perú**. 24. Retrieved from http://www.proyecto-cbc.org.pe/admin/recursos/publicaciones/b32f1-Analisis_De_Perdida_De_Cobertura_Forestal.pdf. Lima-Perú, 2015.

MINAM. Ministerio del Ambiente. **Mapa de pérdida de los Bosques Húmedos Amazónicos del Perú 2000 - 2011 - Memoria Descriptiva**. Lima Perú, 2014.

MINAM. Ministerio del Ambiente. **El Perú y el Cambio Climático. Tercera Comunicación Nacional del Perú**. En Convención Marco de las Naciones Unidas sobre Cambio Climático. Disponible en: <http://www.minam.gob.pe/wp-content/uploads/2016/05/Tercera-Comunicación.pdf>. Lima Perú, 2016. Consultado enero 2019.

MINAM. Ministerio del Ambiente. Decreto Supremo Ministerial. N°007-2016-MINAM. Lima Perú, 2016. Consultado enero 2018.

MINAGRI. Ministerio de Agricultura y Riego. Decreto Supremo Ministerial N ° 018. Lima, Perú, 2015.

MINAM & MINAGRI. Ministerio del Ambiente & Ministerio de Agricultura. **El Perú de los bosques**. Lima – Perú, 2012.

MTC. Ministerio de Transportes y Comunicaciones, Viceministerio de Transportes. **Mapeo con imágenes del satélite peruano perusat-1 y clasificación de la carretera central. tramo: Puente los Ángeles (Lima) – Puente Ricardo Palma (Huarochiri)**. Lima Perú, 2017. Disponible en: http://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/Imagen_Satelital/4_Mapeo_Imag_PeruSat-1_PE-22_Pte_Los_Angeles_Pte_Ricardo_Palma_Set-2017.pdf. Consultado enero 2019.

MOLINERO, L. **Medidas de concordancia para variables cualitativas**. Asociación de la Sociedad Española de Hipertensión. (en línea). España, 2001. Disponible en <http://www.seh-lelha.org/pdf/concor2.pdf>. Consultado marzo 2018.

NASA. Administración Nacional de la Aeronáutica y del Espacio. Disponible en <https://www.lanasa.net/>. 2016.

NAVARRO, R. M. & HERNÁNDEZ, R. “**Cartografía de Variables eco fisiológicas en repoblaciones de pino a partir de datos Hiperespectrales**”. Presentado en V Congreso Forestal Español, Montes y Sociedad: Saber qué hacer, Ávila, España, 2009.

NEUBERT, M., & MEINEL, G. Evaluation of segmentation programs for high resolution remote sensing applications. In International ISPRS Workshop “High Resolution Mapping from Space”. p.6-8., 2003

OAS. Organización de los Estados Americanos Capitulo 4. **Percepción remota en la evaluación de peligros naturales**. 1–25p., 2009.

OLAYA, V., PATIÑO NARVÁEZ, N. A. **Sistemas de Información Geográfica**. 2011.

OLOFSSON, P., FOODY, G. M., STEHMAN, S. V., & WOODCOCK, C. E. **Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation**. *Remote Sensing of Environment*, 129, 122–131p, 2013. Disponible en: <https://doi.org/10.1016/j.rse.2012.10.031>. Consultado julio 2019.

OTCA. Organización del Tratado de Cooperación. **Amazónica. El cambio Climático en la Región Amazónica**, 2014. Disponible en: www.otca-oficial.info Consultado mayo 2019.

PAULINA OSORIO, L., MAS, J. F., GUERRA, F., & MAASS, M. **Análisis y modelación de los procesos de deforestación: un caso de estudio en la cuenca del río Coyuquilla**, Guerrero, México. *Investigaciones Geográficas*,

2015(88), 60–74. Disponible en: <https://doi.org/10.14350/rig.43853>. 2015. Consultado setiembre 2018.

PLANET LABS. <https://www.planet.com/company/>.2019. Consultado abril 2019.

POMPA, M. **Análisis de la deforestación en ecosistemas montañosos del noroeste de México**. Avances En Investigación Agropecuaria, 12(2), 35–44p, 2008.

PCI GEOMATICA. Disponible en: <https://www.pcigeomatics.com/>. 2018.

PEÑA, J. **Efectos Ecológicos De Los Cambios De Coberturas Y Usos Del Suelo En La Marina Baixa** (ALICANTE). Universidad de Alicante. España, 2007.

PERZ, S. G. The Changing Social Contexts of Deforestation in the Brazilian Amazon. Social Science Quarterly, 83(1), 35–52p. Disponible en: <https://doi.org/10.1111/1540-6237.00069>, 2002.

PLANET LABS. **Planet Imagery Product Specification**. 56. Disponible en: https://www.planet.com/products/satellite-imagery/files/Planet_Imagery_Product_Specs.pdf, 2016.

PNUD. Comité Técnico Interagencial del Foro de Ministros de Medio Ambiente de América Latina y el Caribe, 2000. Disponible en: <http://www.pnuma.org/forodeminstros/12-barbados/bbdt03e-BosquesTropicalesHumedoss.pdf>.

PONZONI, F. J., & KUPLICH, T. M. **Sensoriamento Remoto da Vegetação. 2–4. Raney R., Principles & Applications of imagin radar**, 2015.

OTCA, Organización del Tratado de la Cooperación Amazónica. **El cambio climático en la región Amazónica**, Acciones de la Organización del Tratado de la Cooperación Amazónica, 2014.

PULGAR VIDAL, Javier. **Geografía del Perú: Las ocho regiones naturales**. Editorial Ausonia. Lima-Perú, 1967.

PULGAR, M., OTÁLORA, V., SUÁREZ, G., & CALMET, F. **Nivel de Referencia de Emisiones Forestales propuesto por Perú**. Lima-Perú, 2015.

RAISG. Red Amazónica de información Socioambiental Georreferenciada. **Plataforma de RAISG**. <https://www.amazoniasocioambiental.org/es/>. 2019. Consultado en agosto 2019.

RAISG. Red Amazónica de Información Socioambiental Georreferenciada. **Deforestación en la Amazonia: (1970-2013)**. Brasilia-Brasil, 2015.

RANEY, K. **A matter of survival: On being visually literate**, The English and Media Magazine, vol.39, pp.37-42. 1998.

RICHARDS, J. A. **Remote sensing digital image analysis: An introduction. In Remote Sensing Digital Image Analysis: An Introduction** (Vol. 9783642300622), 2013. Disponible en: <https://doi.org/10.1007/978-3-642-30062-2>. Consultado junio 2019.

RIVERA CALDRÓN, V. S. **Tradicionistas y murrasianos José de la Riva-Agüero**. 2012.

RODRIGUEZ, E; ARREDONDO, H. **Manual Para El Manejo Y Procesamiento De Imágenes Satelitales Obtenidas Del Sensor Remoto Modis De La Nasa, Aplicado En Estudios De Ingeniería Civil**. Pontificia Universidad Javeriana Facultad De Ingeniería, Bogotá D.C. Colombia, 2005.

RODRÍGUEZ-GALIANO, V., & CHICA-RIVAS, M. **Clasificación de imágenes de satélite mediante software libre: nuevas tendencias en algoritmos de Inteligencia Artificial**. XV Congreso Nacional de Tecnologías de La Información Geográfica, 19–21p., 2012.

ROKACH, L., & MAIMON, O. **Data Mining With Decision Trees** (2nd ed.; U. H. Bunke (Univ. Bern, Switzerland) P. S. P. Wang (Northeastern Univ., ed.), 2015.

SÁNCHEZ, A. **Análisis Multitemporal de la Cobertura de la Tierra en la Cuenca del Valle de Jesús de Otoro entre los años 2000 – 2006 Aplicando Técnicas de Teledetección**. Universidad Nacional Autónoma de Honduras. 146 p., 2009.

SÁNCHEZ, P. **La teledetección enfocada a la obtención de mapas digitales**. Universidad de Cuenca Ecuador, 2012.

SENTINEL a. Actualizado 2018. Disponible en: <http://www.geodim.es/pdf/Geodim%20SENTINEL-2A.pdf>. <https://scihub.copernicus.eu/>. Consultado junio 2018.

SENTINEL b. Actualizado 2018. Disponible en: <http://www.geodim.es/pdf/Geodim%20SENTINEL-2A.pdf> (2018). Consultado junio 2018.

SERFOR. Servicio Nacional Forestal y de Fauna Silvestre. **Cobertura y Deforestación en los Bosques Húmedos Amazónicos al 2017** (p. 14). p. 14. Lima-Perú, 2017.

SERFOR. Servicio Nacional Forestal y de Fauna Silvestre, Ministerio del Ambiente, M. del, FAO, & Finlandia. **Marco Metodológico del Inventario Nacional Forestal y de Fauna Silvestre**. Lima, Perú, 2016.

SMITH, J., SABOGAL, C., DE JONG, W., & KAIMOWITZ, D. Center for International Forestry Research. **Bosques secundarios como recurso para el desarrollo rural y la conservación ambiental en los típicos de América Latina The CGIAR System**. 1997.

SKJONG, R., & WENTWORTH, B. H. **Expert judgment and risk perception. Proceedings of the International Offshore and Polar Engineering Conference.** 4, 537–544. 2001.

STEHMAN; S.V., & CZAPLEWSKI, R.L. **Design and analysis for thematic map accuracy assessment: fundamental principles. Remote Sensing of Environment.** V64, n3, p331-334, 1998.

STRAHLER, A. H.; BOSCHETTI, L.; FOODY, G. M.; FRIEDL, M. A.; HANSEN, M. C.; HEROLD, M.; MAYAUX, P.; MORISETTE, J. T.; STEHMAN, S. V.; WOODCOCK, C. E. **Global land cover validation: Recommendations for evaluation and accuracy assessment of global land cover maps.** Luxembourg, 2006, v. 51, n. 4, 58 p. (EUR 22156 EN). Disponible en: <<https://landval.gsfc.nasa.gov/pdf/GlobalLandCoverValidation.pdf>>. Consultado: agosto 2019.

T. TOUTIN. **ROS and SEASAT image Geometric Correction** IEEE-IGARS, Vol. 30 No 3, pp 603-609. 1992.

ZAMORA, S; LÓPEZ, T; RODRÍGUEZ J; BLANCO, M. **Metodología de validación de los mapas de usos de la tierra de Nicaragua.** Ministerio del Ambiente y los Recursos Naturales de Marena. NI. 17 p. Nicaragua, 2016.

ANEXO 1 – IMÁGENES SATELITALES PARA ANÁLISIS

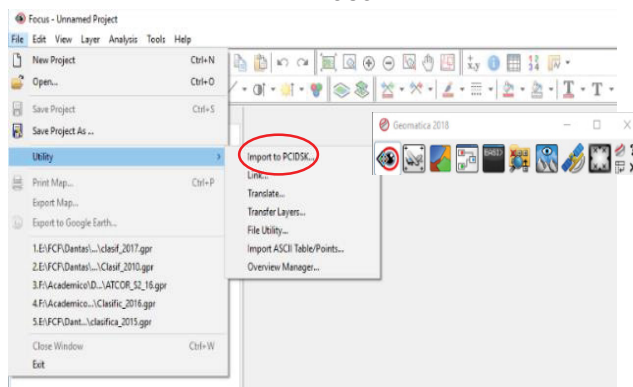
Adquisición: <https://scihub.copernicus.eu/>

Sensor	Fecha	Código original	R. Espacial
S2A	Agosto 2016	S2A_MSIL1C_20160804T151712_N0204_R125_T18LVR_20160804T151708.SAFE	10 m
		S2A_MSIL1C_20160804T151712_N0204_R125_T18LWR_20160804T151708.SAFE	
		S2A_MSIL1C_20160804T151712_N0204_R125_T18MW_S_20160804T151708.SAFE	
		S2A_MSIL1C_20160824T151702_N0204_R125_T18MV_S_20160824T151705.SAFE	
	Set 2018	S2A_MSIL1C_20180913T151701_N0206_R125_T18LVR_20180913T185416.SAFE	10 m
		S2A_MSIL1C_20180913T151701_N0206_R125_T18LWR_20180913T185416.SAFE	
		S2A_MSIL1C_20180913T151701_N0206_R125_T18MV_S_20180913T185416.SAFE	
		S2A_MSIL1C_20180913T151701_N0206_R125_T18MW_S_20180913T185416.SAFE	
S1A	Mayo 2015	s1a-iw-grd-vv-20150521t103747-20150521t103812-006018-007c2a-001	30 m Re proyectado a 10 m
		s1a-iw-grd-vh-20150521t103747-20150521t103812-006018-007c2a-002	
	Junio 2019	s1a-iw-grd-vv-20190601t232653-20190601t232722-027492-031a2d-001	30 m Re proyectado a 10 m
		s1a-iw-grd-vh-20190601t232653-20190601t232722-027492-031a2d-002	

FUENTE: La autora (2019).

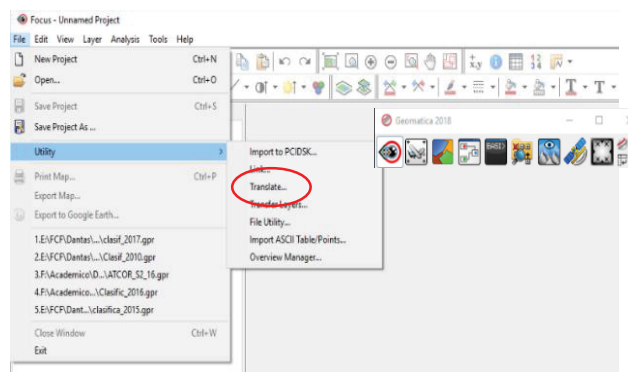
ANEXO 2 – ETAPAS PARA LA UNIÓN DE BANDAS SATELITALES (PCI GEOMÁTICA 2018)

Paso 1



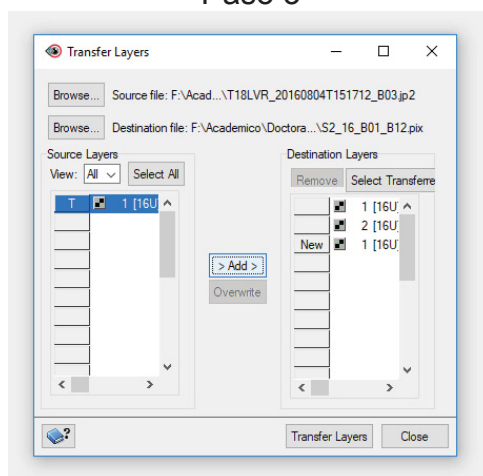
Importar la Banda 1 con extensión TIFF para transformar a la extensión pix, aquí fue colocado el nombre del archivo a unir

Paso 2



Transferir las bandas deseadas

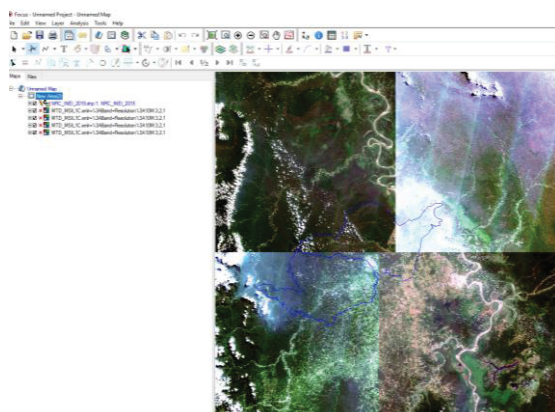
Paso 3



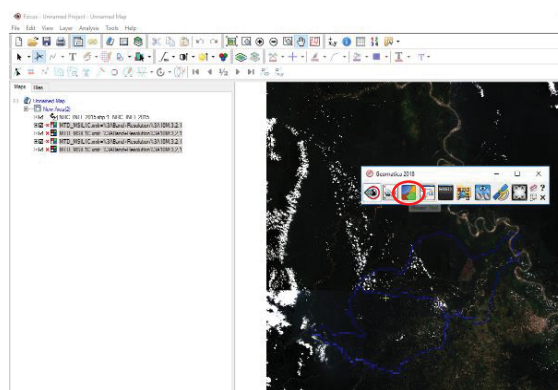
Unión de bandas

ANEXO 3 – ETAPAS DE LA GENERACIÓN DEL MOSAICO SATELITAL (PCI GEOMÁTICA 2018)

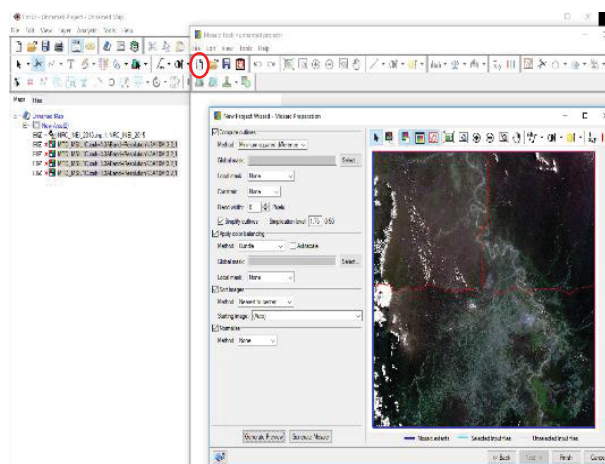
Paso 1: Despliegue de las cuatro imágenes Sentinel 2 A. Archivo *.safe



Paso 2: Generación del mosaico




Paso 3




ANEXO 4 – ETAPAS PARA LA GENERACIÓN DE SEGMENTOS (PCI GEOMÁTICA 2018)

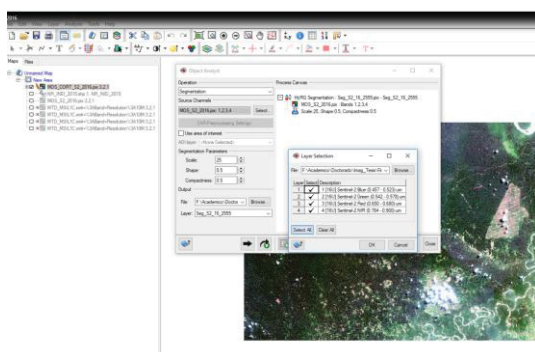
Paso 1: Seleccionar la opción de segmentos y selección de scale, shape y compactenes



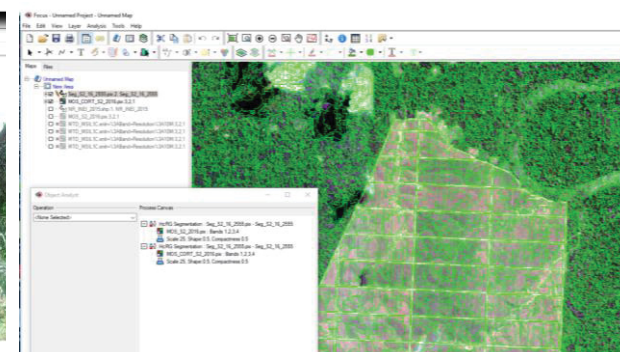
Paso 2: Asignación de valores




Paso 3: Proceso de segmentación



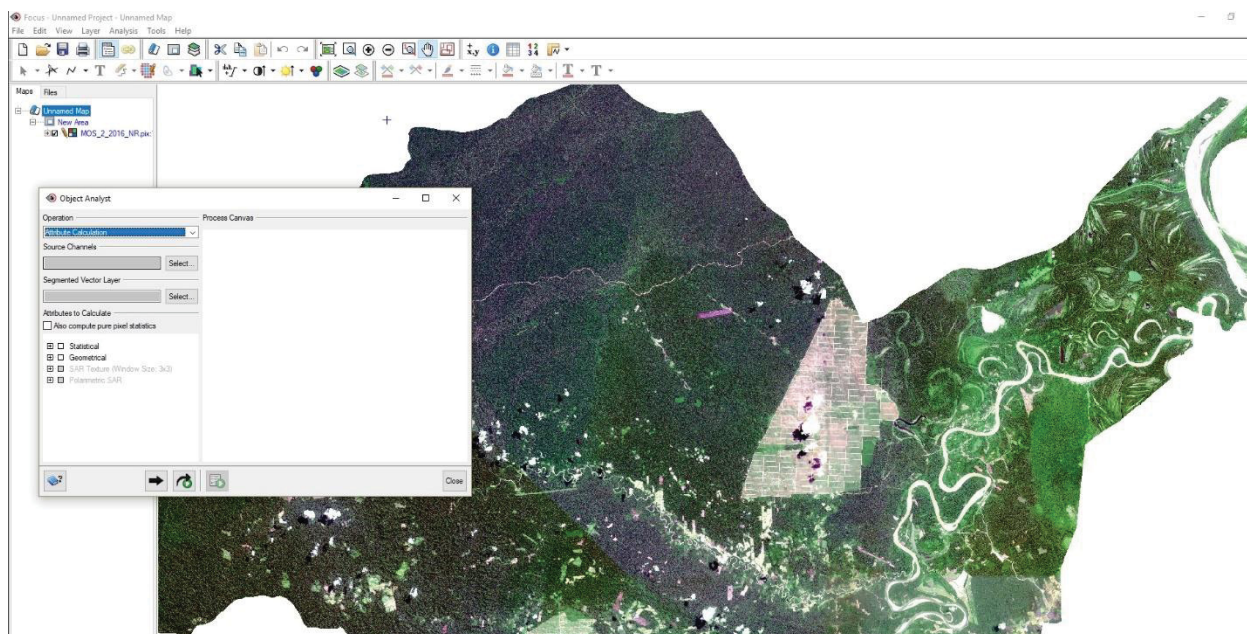
Paso 4: Segmentos generados



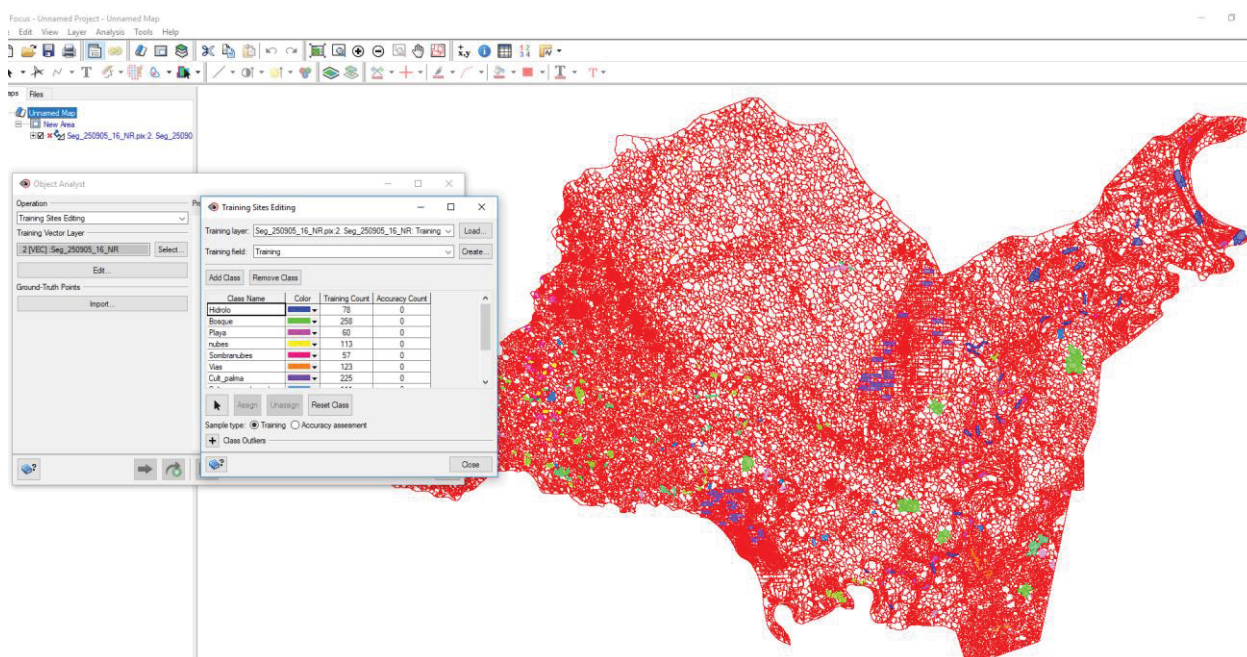
Segmentos de los mosaicos año 2016 y año 2018



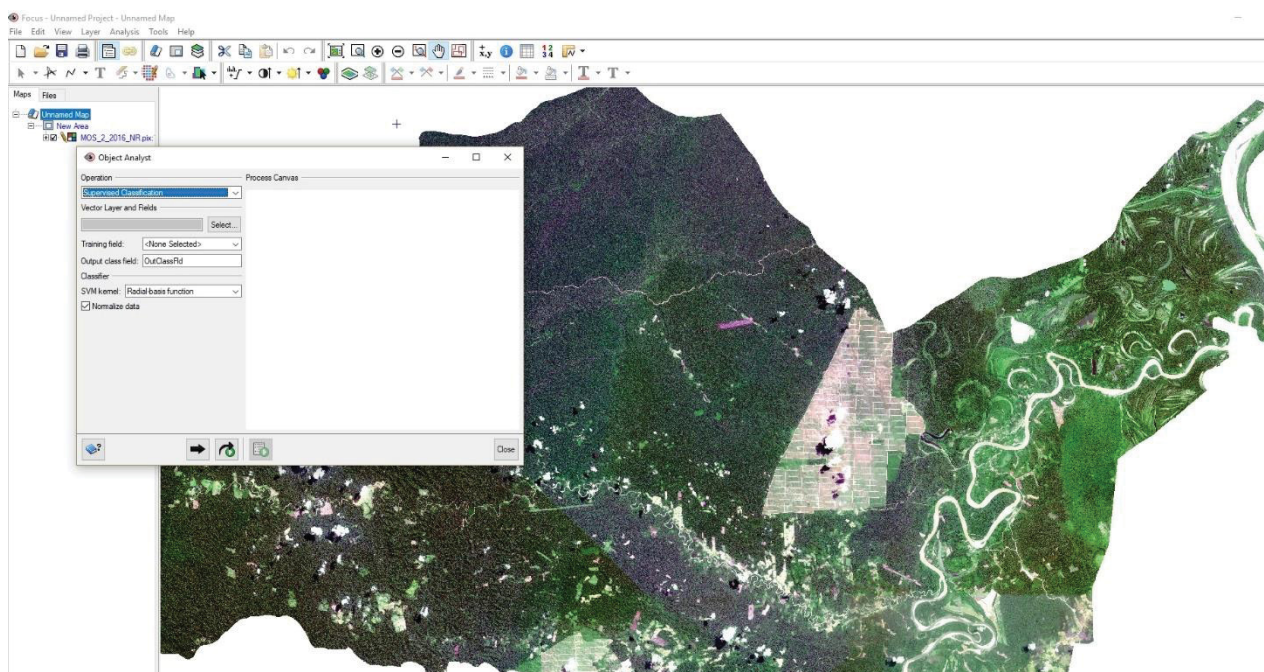
ANEXO 5 - CÁLCULO DE ATRIBUTOS (PCI-GEOMÁTICA 2018)



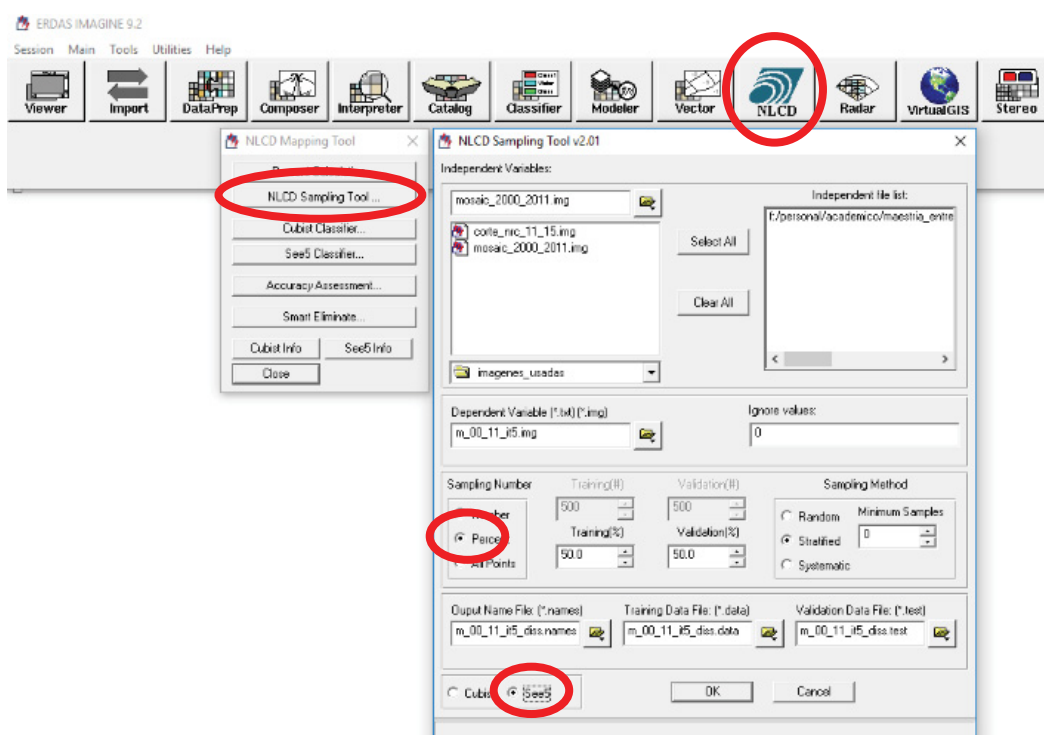
ANEXO 6 - ÁREAS DE ENTRENAMIENTOS (PCI-GEOMÁTICA 2018)



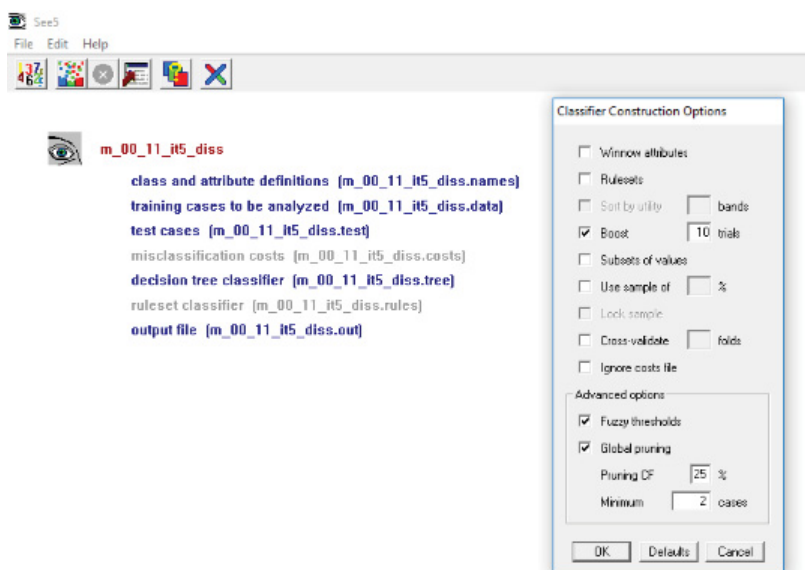
ANEXO 7 - CLASIFICACIÓN ALGORITMO SVM (PCI-GEOMÁTICA 2018)



ANEXO 8 - ADECUACIÓN DE ÁREAS DE ENTRENAMIENTO ÁRBOLES DE DECISIÓN (ERDAS IMAGE 9.2)



ANEXO 9 - REGLAS DE SALIDA DE LA CLASIFICACIÓN (SEE 5 / C5)



ANEXO 10 - RESULTADO ARCHIVO *.names (SEE 5 / C5)

c12_a_5050: Bloc de notas

Archivo Edición Formato Ver Ayuda

Generated with cubistinput v2.0 by MDA Federal

Sampling option : Percentage

Training percent requested : 50.00

Validation percent requested: 50.00

Minimum samples requested : 0

Ignored values : 0

Training samples present : 60108

Validation samples present : 60107

Sample method : Stratified Random

Output format : See5

lep. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/seg_250905_1618_f.img(:Layer_1)

(coord: ignore.

'coord: ignore.

band01: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_1)

band02: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_2)

band03: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_3)

band04: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_4)

band05: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_5)

band06: continuous. |f:/academico/doctorado/imag_tesis/final_nr/s2_20160804/3_1_clasif_16_ago19/3_1_arbol/mos_s2_1618.img(:Layer_6)

lep: 1010,1030,1111,1140,1150,2010,2020,2030,2040,2050,2060,2070,2080,2090,2099,3010,3030,3040,4010,4011,4020,4030,4040,4070,4080,4090

Píxeles totales de
entrenamiento

Variable
Indepen-
diente

Variables Dependiente (clases)

ANEXO 11 - RESULTADO ARCHIVO *.tree (SEE 5 / C5)

```

Options:
  10 boosting trials
  Probability thresholds

Class specified by attribute `dep'

Read 60108 cases (9 attributes) from c12 a 5050.data

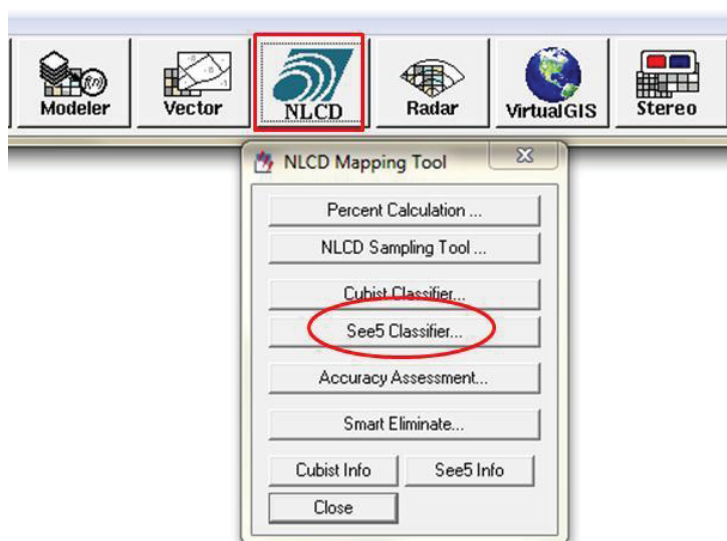
----- Trial 0: -----

Decision tree:

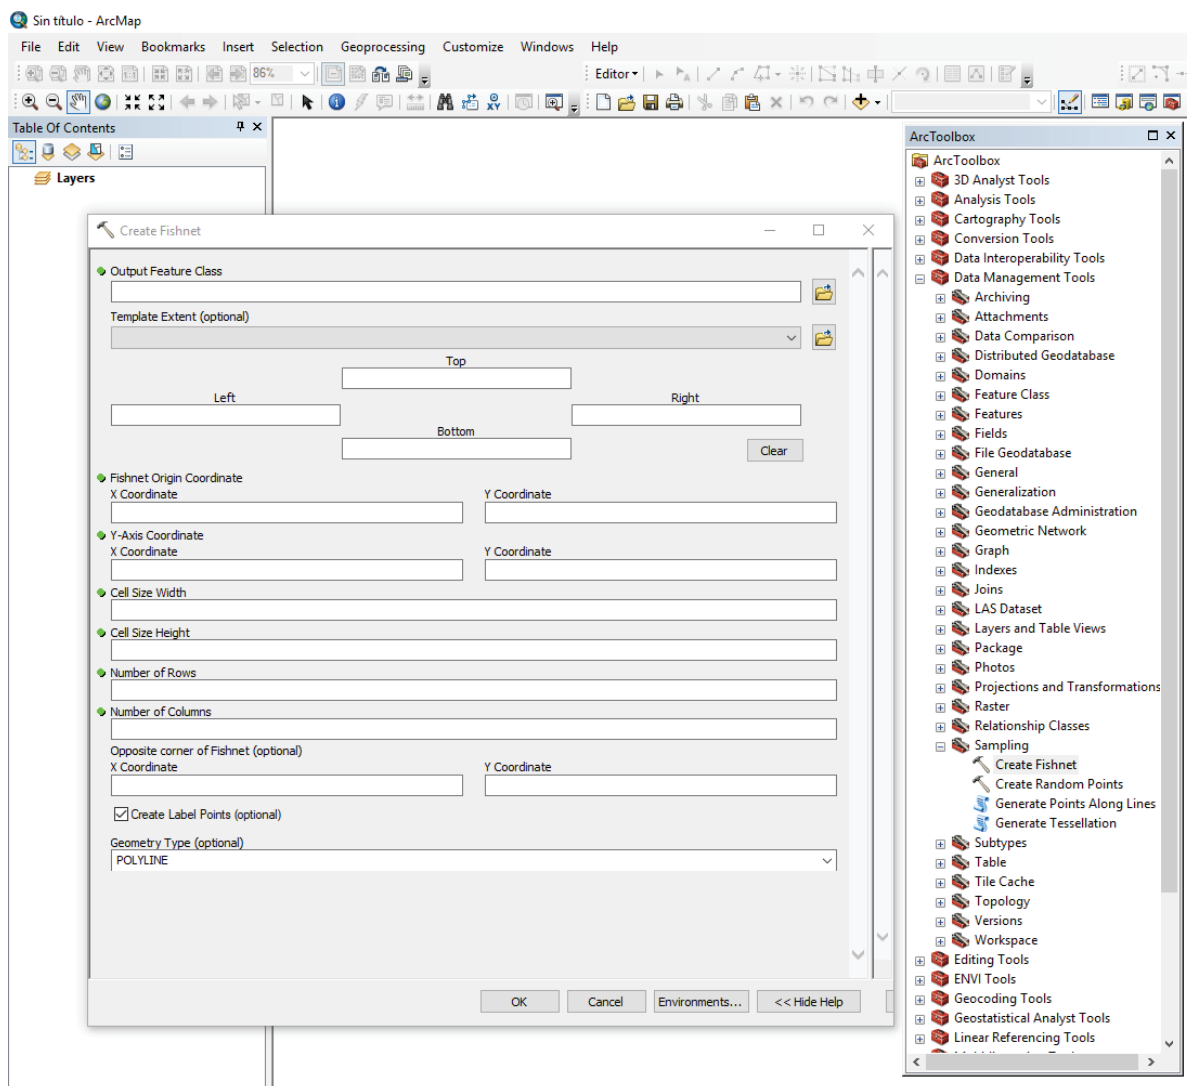
band01 >= 2532 (2531.5):
...band02 >= 5167 (5166.5):
: ...band06 >= 8600 (8334):
: : ...band01 <= 6233 (6314):
: : : ...band03 <= 6365 (6373.5):
: : : : ...band06 <= 9818 (9980.5): 2030 (152/3)
: : : : band06 >= 10095 (9980.5): 1140 (15)
: : : band03 >= 6378 (6373.5):
: : : : ...band01 <= 4369 (4380):
: : : : : ...band06 <= 8486 (8559):
: : : : : : ...band03 <= 6429 (6763.5): 1010 (4/2)
: : : : : : band03 >= 7225 (6763.5): 4030 (2/1)
: : : : : band06 >= 8584 (8559):
: : : : : : ...band02 >= 5501 (5500.5): 1030 (727)
: : : : : : band02 <= 5500 (5500.5):
: : : : : : ...band04 >= 8128 (8124): 2030 (5)
: : : : : : band04 <= 8120 (8124):
: : : : : : : ...band06 <= 9110 (9118): 2030 (3/1)
: : : : : : : band06 >= 9126 (9118): 1030 (14)
: : : band01 >= 4399 (4380):
: : : : ...band06 >= 14018 (11198.5): 1140 (11)
: : : : band06 <= 9764 (11198.5):
: : : : : ...band03 >= 7949 (7706):
: : : : : : ...band04 <= 5546 (5956): 4040 (3)
: : : : : : band04 >= 6366 (5956): 4030 (5)
: : : : : : band03 <= 7594 (7706):

```

ANEXO 12 - CLASIFICACIÓN SUPERVISADA (ERDAS IMAGE 9.2)



ANEXO 13 – GENERACIÓN DE RED DE PUNTOS PARA VALIDAR



ANEXO 14 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 1

UNIÓN	PESTAÑA	TRAIN					TEST					Promedio ponderado tasa de error	Promedio tasa de error	MISMA CLASE	CAMBIO DE CLASE
		COLUMNA	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR	COLUMNA	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR						
1	C1C7	TRAINING	6114	5132	16.1%	GC_C1_16	6114	32	99.5%	79.7%	81.5%	100.0%	0.0%		
	C1C7	C7_B_18	5100	4304	15.6%	CG_C7_18	5100	2041	60.0%						
2	C1C8	TRAINING	253762546	211663371	16.6%	GC_C1_16	253762546	879700	99.7%	80.0%	82.6%	42.1%	57.9%		
	C1C8	C8_B_18	192970536	175968770	8.8%	CG_C8_18	192970536	76648686	60.3%						
3	C1C9	TRAINING	253762546	211663371	16.6%	GC_C1_16	253762546	879700	99.7%	81.6%	84.0%	40.2%	59.8%		
	C1C9	C9_B_18	192970536	161665748	16.2%	c9_b_18	192970536	70408193	63.5%						
4	C1C10	TRAINING	1865583901	1535682100	17.7%	GC_C1_16	1865583901	2149249	99.9%	61.9%	99.9%	9.2%	90.8%		
	C1C10	C10	230104	187509	18.5%	C10	230104	175138	23.9%						
5	C1C11	TRAINING	583384468	476394389	18.3%	GC_C1_16_	583384468	1294080	99.8%	62.2%	99.8%	14.7%	85.3%		
	C1C11	C11	322146	257362	20.5%	C11	138062	103960	24.7%						
1	C2C7	TRAINING	6114	5600	8.4%	GC_C2_16	6114	20	99.7%	79.8%	81.6%	39.8%	60.2%		
	C2C7	C7_B_18_Ci	5100	4304	15.6%	CG_C7_18	5100	2041	60.0%						
2	C2C8	TRAINING	6114	5600	8.4%	GC_C2_16	6114	20	99.7%	78.1%	80.0%	40.3%	59.7%		
	C2C8	C8_B_18	5100	4741	7.0%	CG_C8_18	5100	2219	56.5%						
3	C2C9	TRAINING	6114	5600	8.4%	GC_C2_16	6114	20	99.7%	80.0%	81.7%	40.0%	60.0%		
	C2C9	C9_B_18_Ci	5100	4338	14.9%	CG_C9_18	5100	2028	60.2%						
4	C2C10	TRAINING	37176	30817	17.1%	GC_C1_16	37176	41	99.9%	61.9%	34.5%	9.3%	90.7%		
	C2C10	C10	230104	187509	18.5%	C10	230104	175138	23.9%						
5	C2C11	TRAINING	14230	12972	8.8%	GC_C2_16	14230	55	99.6%	62.2%	31.7%	14.4%	85.6%		
	C2C11	C11	322146	257362	20.5%	C11	138062	103960	24.7%						
1	C4C7	C7_B_18_Ci	5100	4304	15.6%	CG_C7_18	5100	2041	60%	41.4%	23.6%	17.8%	82.2%		
	C4C7	C4	247187	204367	17.3%	C4	247187	190937	23%						
2	C4C8	C8_B_18	7812	7217	7.6%	CG_C8F_18	7812	3087	60%	41.6%	24.0%	17.4%	82.6%		
	C4C8	C4	247187	204367	17.3%	C4	247187	190937	23%						

3	C4C9	C9_B_18	7812	7217	7.6%	GC_C9f_18	7812	2781	64%	43.6%	24.1%	16.8%	83.2%
	C4C9	C4	247187	204367	17.3%	C4	247187	190937	23%				
4	C4C10	C4	247187	204367	17.3%	C4	247187	190937	23%	23.4%	23.3%	11.4%	88.6%
	C4C10	C10	230104	187509	18.5%	C10	230104	175138	24%				
5	C4C11	C4	247187	204367	17.3%	C4	247187	190937	23%	23.8%	23.5%	11.3%	88.7%
	C4C11	C11	322146	257362	20.5%	C11	138062	103960	25%				
1	C5C7	C7_B_18	8319	6922	16.8%	CG_C7_18	8319	3031	64%	43.4%	25.3%	17.3%	82.7%
	C5C7	C5	346062	280907	18.8%	C5	148312	113950	23%				
2	C5C8_	C8_B_18	8319	7687	7.6%	CG_C8_18	8319	3380	59%	41.3%	25.1%	17.0%	83.0%
	C5C8	C5	346062	280907	18.8%	C5	148312	113950	23%				
3	C5C9	C9_B_18	8319	7126	14.3%	CG_C9_18	8319	3080	59%	41.3%	25.1%	16.4%	83.6%
	C5C9	C5	346062	280907	18.8%	C5	148312	113950	23%				
4	C5C10	C5	346062	280907	18.8%	C5	148312	113950	23%	23.6%	23.6%	11.4%	88.6%
	C5C10	C10	230104	187509	18.5%	C10	230104	175138	24%				
5	C5C11	C5	346062	280907	18.8%	C5	148312	113950	23%	24.0%	23.9%	11.3%	88.7%
	C5C11	C11	322146	257362	20.5%	C11	138062	103960	25%				
1	C6C7	c7_b_18	8258	6850	17.1%	clasi_c7_cl	8258	6931	16%	19.7%	22.7%	17.4%	82.6%
	C6C7	C6	395499	321300	18.8%	C6	98875	96580	23%				
2	C6C8	C8_B_18	8259		100.0%	CG_C8_18	8259	3303	60%	41.7%	26.1%	17.0%	83.0%
	C6C8	C6	395499	321300	18.8%	C6	98875	96580	23%				
3	C6C9	C9_B_18	8258	6978	15.5%	CG_C9_18	8258	2972	64%	43.7%	26.4%	16.4%	83.6%
	C6C9	C6	395499	321300	18.8%	C6	98875	96580	23%				
4	C6C10	C6	395499	321300	18.8%	C6	98875	96580	23%	23.6%	23.7%	11.3%	88.7%
	C6C10	C10	230104	187509	18.5%	C10	230104	175138	24%				
5	C6C11	C6	395499	321300	18.8%	C6	98875	96580	23%	24.0%	24.1%	11.2%	88.8%
	C6C11	C11	322146	257362	20.5%	C11	138062	103960	25%				

ANEXO 15 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 2

UNIÓN	AÑO	PESTAÑA	TRAIN				TEST				Promedio ponderado tasa de error	MISMA CLASE	CAMBIO DE CLASE
			COLUMNA	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR	COLUMNA	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR			
1	2015	C2226	C22_VH_15_	5743	1783	69.0%	C22VHB15	5736	260	95.5%	93.3%	7.8%	92.2%
	2019	C2226	C26_VH_19	4464	1431	67.9%	C26_VHF_19	4464	398	91.1%			
2	2015	C2227	C22_VH15	5736	1783	68.9%	C22_VHB15	5736	1093	80.9%	83.8%	17.9%	82.1%
	2019	C2227	C27_VV_19	4464	1178	73.6%	C27_VVF_19	4464	596	86.6%			
3	2015	C2228	C22VH15	5333	2102	60.6%	C22VHB15	5333	445	91.7%	78.1%	15.8%	84.2%
	2019	C2228	C28	203247	71864	64.6%	C28	203247	71879	64.6%			
4	2015	C2229	C22VH15	3921	1483	62.2%	C22VHB15	3921	368	90.6%	77.7%	20.6%	79.4%
	2019	C2229	C29	284546	100422	64.7%	C29	121948	43070	64.7%			
5	2015	C2230	C22VH15	2786	996	64.2%	C22VHB15	2786	294	89.4%	77.1%	25.9%	74.1%
	2019	C2230	C30	203247	71936	64.6%	C30	203247	71826	64.7%			
6	2015	C2231	C22_VH_15_	2585	920	64.4%	C22_VHB_15	2585	282	89.1%	76.8%	27.3%	72.7%
	2019	C2231	C31	284546	100643	64.6%	C31	121948	43116	64.6%			
1	2015	C2326	C23_Vv_15_	5736	2023	64.7%	CC23VVB15	5736	760	86.8%	81.1%	6.9%	93.1%
	2019	C2326	C26VH19	4464	1431	67.9%	C26_VHF_19	4464	1092	75.5%			
2	2015	C2327	C23_Vv15	5736	2023	64.7%	C23_VvB15	5736	760	86.8%	83.5%	19.4%	80.6%
	2019	C2327	C27_VV_19	4464	1178	73.6%	C27_VVF_19	4464	884	80.2%			
3	2015	C2328	C23Vv15	5333	2283	57.2%	C23VvB15	5333	392	92.6%	78.6%	16.9%	83.1%
	2019	C2328	C28	203247	71864	64.6%	C28	203247	71879	64.6%			
4	2015	C2329	C23VH15	3921	1645	58.0%	C23VvB15	3921	321	91.8%	78.3%	21.8%	78.2%
	2019	C2329	C29	284546	100422	64.7%	C29	121948	43070	64.7%			
5	2015	C2330	C23_Vv_15_	3921	1645	58.0%	C23VvB15	3921	321	91.8%	78.3%	26.7%	73.3%
	2019	C2330	C30	203247	71936	64.6%	C30	203247	71826	64.7%			
6	2015	C2331	C23_Vv_151	2585	934	63.9%	C23VVB15	2585	996	91.8%	78.2%	28.0%	72.0%

1	2019	C2331	C31	284546	100643	64.6%	C31	121948	43116	64.6%	65.4%	55.7%	6.5%	93.5%
	2015	C2426	C24	228563	101836	55.4%	C24	228563	101787	55.5%	65.4%	55.7%	6.5%	93.5%
	2019	C2426	C26_VH_19	2327	573	75.4%	C26_VHF_19	2327	573	75.4%				
2	2015	C2427	C24	228563	101836	55.4%	C24	228563	101787	55.5%	59.3%	55.6%	7.8%	92.2%
	2019	C2427	C27_VV_19	2327	858	63.1%	C27_VVF_19	2327	858	63.1%				
3	2015	C2428	C24	228563	101836	55.4%	C24	228563	101787	55.5%	60.1%	59.8%	7.2%	92.8%
	2019	C2428	C28	203247	71864	64.6%	C28	203247	71879	64.6%				
4	2015	C2429	C24	228563	101836	55.4%	C24	228563	101787	55.5%	60.1%	58.7%	9.3%	90.7%
	2019	C2429	C29	284546	100422	64.7%	C29	121948	43070	64.7%				
5	2015	C2430	C24	228563	101836	55.4%	C24	228563	101787	55.5%	60.1%	59.8%	4.7%	95.3%
	2019	C2430	C30	203247	71936	64.6%	C30	203247	71826	64.7%				
6	2015	C2431	C24	228563	101836	55.4%	C24	228563	101787	55.5%	60.1%	58.7%	4.7%	95.3%
	2019	C2431	C31	284546	100643	64.6%	C31	121948	43116	64.6%				
1	2015	C2526	C25	228563	100024	56.2%	C25	228563	99907	56.2%	65.8%	56.4%	0.8%	99.2%
	2019	C2526	C26_VH_19	2327	573	75.4%	C26_VHF_19	2327	573	75.4%				
2	2015	C2527	C25	228563	100024	56.2%	C25	228563	99907	56.2%	59.7%	56.3%	4.4%	95.6%
	2019	C2527	C27_VV_19	2327	858	63.1%	C27_VVF_19	2327	858	63.1%				
3	2015	C2528	C25	228563	100024	56.2%	C25	228563	99907	56.2%	60.4%	60.2%	5.6%	94.4%
	2019	C2528	C28	203247	71864	64.6%	C28	203247	71879	64.6%				
4	2015	C2529	C25	228563	100024	56.2%	C25	228563	99907	56.2%	60.5%	59.2%	6.7%	93.3%
	2019	C2529	C29	284546	100422	64.7%	C29	121948	43070	64.7%				
5	2015	C2530	C25	228563	100024	56.2%	C25	228563	99907	56.2%	60.5%	60.2%	3.9%	96.1%
	2019	C2530	C30	203247	71936	64.6%	C30	203247	71826	64.7%				
6	2015	C2531	C25	228563	100024	56.2%	C25	228563	99907	56.2%	60.4%	59.1%	3.9%	96.1%
	2019	C2531	C31	284546	100643	64.6%	C31	121948	43116	64.6%				
1	2019	C3226	C26_VH_19	2375	543	77.1%	C26_VVF_19	2375	583	75.5%	65.4%	55.7%	0.8%	99.2%
	2015	C3226	C32	319988	142515	55.5%	C32	137138	61100	55.4%				
2	2015	C3227	C27_VV_19	4464	1178	73.6%	C27_VVF_19	4464	1178	73.6%	64.5%	56.0%	19.4%	80.6%
	2019	C3227	C32	319988	142515	55.5%	C32	137138	61100	55.4%				

3	2019	C3228	C32	319988	142515	55.5%	C32	137138	61100	55.4%	60.0%	60.9%	7.0%	93.0%
	2015	C3228	C28	203247	71864	64.6%	C28	203247	71879	64.6%				
4	2019	C3229	C32	319988	142515	55.5%	C32	137138	61100	55.4%	60.1%	59.8%	9.0%	91.0%
	2015	C3229	C29	284546	100422	64.7%	C29	121948	43070	64.7%				
5	2019	C3230	C32	319988	142515	55.5%	C32	137138	61100	55.4%	60.1%	61.0%	4.5%	95.5%
	2015	C3230	C30	203247	71936	64.6%	C30	203247	71826	64.7%				
6	2019	C3231	C32	319988	142515	55.5%	C32	137138	61100	55.4%	60.0%	59.7%	4.5%	95.5%
	2015	C3231	C31	284546	100643	64.6%	C31	121948	43116	64.6%				
1	2019	C3326	C26_VH_19	5218	1461	72.0%	C26_VHF_19	5218	1461	72.0%	64.2%	56.9%	0.8%	99.2%
	2015	C3326	C33	319988	140040	56.2%	C33	137138	59982	56.3%				
2	2019	C3327	C27_VV_19	5218	1970	62.2%	C27_VVF_19	5218	1970	62.2%	59.3%	56.5%	4.4%	95.6%
	2015	C3327	C33	319988	140040	56.2%	C33	137138	59982	56.3%				
3	2019	C3328	C33	319988	140040	56.2%	C33	137138	59982	56.3%	60.5%	61.3%	5.6%	94.4%
	2015	C3328	C28	203247	71864	64.6%	C28	203247	71879	64.6%				
4	2019	C3329	C33	319988	140040	56.2%	C33	137138	59982	56.3%	60.5%	60.3%	6.7%	93.3%
	2015	C3329_	C29	284546	100422	64.7%	C29	121948	43070	64.7%				
5	2019	C3330	C33	319988	140040	56.2%	C33	137138	59982	56.3%	60.5%	61.3%	3.9%	96.1%
	2015	C3330	C30	203247	71936	64.6%	C30	203247	71826	64.7%				
6	2019	C3331	C33	319988	140040	56.2%	C33	137138	59982	56.3%	60.5%	60.2%	4.0%	96.0%
	2015	C3331	C31	284546	100643	64.6%	C31	121948	43116	64.6%				

ANEXO 16 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 3

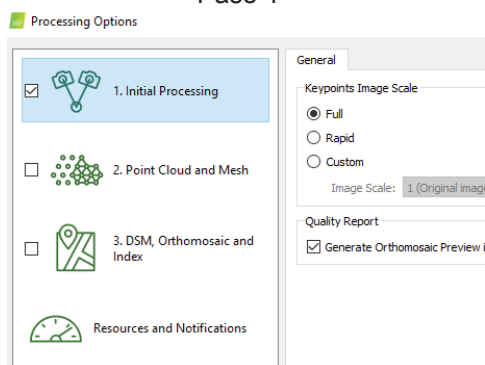
AÑO	PESTAÑA	TEST						MISMA CLASE	CAMBIO DE CLASE
		CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR		
2016-2018	C12_A	60108	59660	0.7%	60107	54593	9.2%	25.7%	74.3%
2016-2018	C13_A	60108	59660	0.7%	60107	54593	9.2%	27.0%	73.0%
2016-2018	C14_A	96172	96088	0.1%	24043	22031	8.4%	26.6%	73.4%
2016-2018	C15_B	272	262	3.7%	272	243	10.7%	51.3%	49.7%
2016-2018	C16_B	272	210	22.8%	272	261	4.0%	54.0%	46.0%
2016-2018	C17_B	272	210	22.8%	272	255	6.3%	49.0%	51.0%

ANEXO 17 - ANÁLISIS TASA DE ERROR DE TRAIN Y TEST DEL MODELO 4

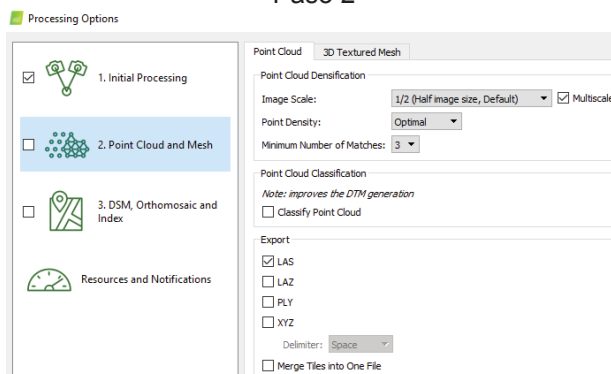
PESTAÑA	TRAINING				TEST			
	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR	CLASIFICADOS TOTAL	CLASIFICADOS CORRECTAMENTE	% ERROR	MISMA CLASE	CAMBIO DE CLASE
C34	272	268	1.5%	272	260	4.4%	46.7%	53.3%
C35	272	259	4.8%	272	260	4.4%	42.9%	57.1%
C36	272	266	2.2%	272	259	4.8%	100.0%	0.0%
C37	272	253	7.0%	272	251	7.7%	44.8%	55.2%
C38	272	259	4.8%	272	272	0.0%	49.2%	50.8%
C39	272	272	0.0%	272	259	4.8%	47.0%	53.0%
C40	272	261	4.0%	272	264	2.9%	51.9%	48.1%
C41	272	266	2.2%	272	245	9.9%	51.3%	48.7%
C42	58603	58325	0.5%	58603	53626	8.5%	32.3%	67.7%
C43	58603	58360	0.4%	58603	53528	8.7%	30.0%	70.0%
C44	58603	58387	0.4%	58603	53514	8.7%	32.3%	67.7%
C45	58603	58387	0.4%	58603	53514	8.7%	30.0%	70.0%
C46	58603	58324	0.5%	58603	53501	8.7%	30.8%	69.2%
C47	82044	82004	0.05%	35162	32430	7.8%	31.6%	68.4%
C48	58603	58360	0.4%	58603	53528	8.7%	32.3%	67.7%
C49	82044	82013	0.04%	35162	32495	7.6%	29.7%	70.3%

ANEXO 18 - VALIDACIÓN MOSAICO DE FOTOGRAFÍAS ÁEREAS (PIX4DMAPPER)

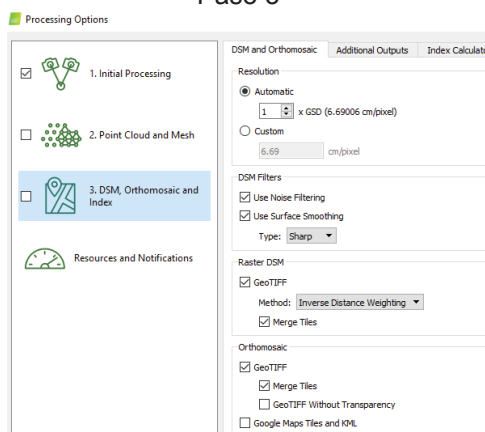
Paso 1



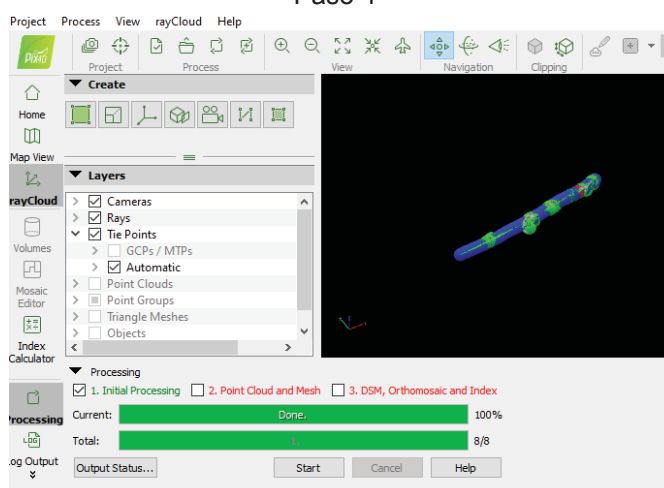
Paso 2



Paso 3



Paso 4



Paso 5

